Commission on the Future of Health Care in Canada

Commission sur l'avenir des soins de santé au Canada

DISCUSSION PAPER NO.35

Influence of Physician Payment Methods on the Efficiency of the Health Care System

by

Michel Grignon, Valérie Paris and Dominique Polton

with the co-operation of

Agnès Couffinhal and Bertrand Pierrard

CREDES, Paris, France

November 2002

103-06752/

Catalogue No. CP32-79/35-2002E-IN

ISBN 0-662-32963-5

Although the views expressed in the papers are those of the authors, each paper was subjected to an independent peer-review process. The Commission would like to thank the Institute of Health Services and Policy Research (IHSPR), of the Canadian Institute of Health Research, for their oversight and administration of the peer-review process. The work of the authors, the reviewers and IHSPR will serve to make these papers an important contribution to the Commission's work and its legacy.

Contents

Abstract iv

Executive Summary v

List of Abbreviations and Meaning vii

General Question 1

Introduction 1

The Various Mechanisms of Physician Payment 3

Part 1: The Economic Literature 5
The Facts and the Simple Theoretical Postulates 5
The Cost-Quality-Fairness Trade-off: Status of the Problem 6
The Cost-Quality-Fairness Trade-off: Discretionary Power of the Physician 7
The Cost-Quality-Fairness Trade-off: The Physician's Capacity to Increase Prescriptions 12

Part 2: In Search of the Optimum Method of Payment: Lessons from a Variety of Experiences 14
Incentive Combinations within Individual Physician Remuneration 14
Different Incentive Combinations at the Individual and Group Levels 18
The Physicians' Group as Locus for Integrating Clinical and Economic Objectives 19
Non-financial Incentives 21

Conclusion: What are the Lessons for the Canadian Context? 22

Specific Questions 23

Notes 26

References 27

Abstract

The study concerns the impact of physician payment methods on the costs of medical care.

There are three main methods of remunerating health care professionals: fee-for-service, capitation and salary. In theory, fee-for-service can lead the professional to generate an excessive volume of care, while lump-sum methods can jeopardize quality and equality of access. The magnitude of these respective risks basically depends on the nature and extent of the physician's discretionary power over the patient. If the physician simply influences demand, risks are limited through the control exercised by the patient; if the physician induces demand, the risks are greater.

There is no satisfactory empirical test of the nature of the physician's discretionary power. However, the majority of experimental studies comparing volume and quality of care according to payment method come to the conclusion that fee-for-service has a significant impact on the volume of service generated by primary care physicians (general practitioners and pediatricians). Conversely, capitation increases referrals and prescriptions, which can impose costs on other health care expenditure budgets. Finally, natural experiments in Norway show that the method of remuneration has less impact than the health characteristics of the patient.

In the real world (outside natural experiments), payment methods are rarely pure:

- First approach: adjust fee-for-service through financial incentives. In the United Kingdom, delegation of a pharmaceutical budget to general practitioners has made it possible to cut down on drug consumption. However, such financial incentives raise fears of conflict of interests between the physician's income and the quality of care he is required to provide. Other incentives are based on performance targets to be achieved, for example screening or immunization. The studies are contradictory, but most indicate that these incentives have a positive impact.
- Second approach: link the level of remuneration to a collective outcome. This type of approach seems ineffective if the group is too large (e.g. all physicians in a country), but payment by capitation of physician groups seems a promising avenue for reconciling cost containment and efficient organization of care.
- Third approach: non-financial incentives (protocols, assessment of practices). Few empirical studies have been conducted on this type of incentives, but initial results indicate a weak impact unless the "messages" are delivered by opinion leaders.

Executive Summary

A large body of economic literature attempts to model the delivery and consumption of health care as a market characterized by several informational asymmetries on which profit is one possible motive of a physician's practice.

Within this literature, we are interested in works dealing with the impact of physicians' modes of payment on the volume of services provided or prescribed to the patient, the quality of these services, and inequality of access to care.

We can distinguish three main modes of physician compensation: fee-for-service, capitation (lump sum payment per patient managed over a given period), and salary. Of course, this typology is simplistic, as most national health care systems combine these three modes of payment. In addition, the fee-for-service payment mode reflects, to some extent, a synthesis of medical care activity.

The following theoretical postulates apply: under a fee-for-service arrangement, the price received by the physician takes into account the fixed as well as the variable costs of his practice, which means that at the margin, an additional medical service will always increase the physician's monetary gain. Fee-for-service thus creates favourable conditions for the provision of more medical services than what the patient wants. If the physician has some control over the patient's demand, fee-for-service will increase the volume of medical services provided. By contrast, under a capitation system, the physician has no reason to produce more medical acts than necessary. On the contrary, the concern is that physicians will limit their effort by restricting patient access to care, especially the intangible resources required for the production of health care, such as the time devoted to the patient, the ability and willingness to listen, and the mental effort spent on the case – what is often called the quality of care. Finally, all lump sum payment arrangements raise the risk of case selection: because physicians receive the same amount for cases requiring varying levels of effort, they will prefer to take the simplest cases.

Also on a theoretical level, the robustness of these postulates will more or less depend on the influence the physician may exert on the consumption of care by patients: a high level of influence magnifies the expected negative effects (increase in the volume of care provided under fee-for-service, inferior quality under capitation), while a certain level of control on the patient's part will tend to dampen these effects. Two models of the physician-patient interaction account for this level of influence : imperfect competition and inducement. In the imperfect competition model, the patient is able to judge his physician's actions, but cannot sanction as severely behaviours that he perceives negatively than under conditions of perfect competition: the imperfect competition comes from the patient's bond with his regular physician, whom he knows personally. In the inducement model, the patient is under stronger influence from his physician and cannot control *ex post* the physician's behaviour, who will be in a position to convince the patient that he is receiving exactly the care he is seeking; any competition thus disappears.

The problem is that no satisfactory empirical test exists to evaluate these two theoretical models. We must then resort to observing physician-patient interactions in a real setting, under different payment methods. In order to make inferences from these observations on the impact of payment methods, we must ensure that the comparison reflects "all other things held constant." Two natural experiments (random assignment of a clinic's physicians among various modes of payment) confirm that fee-for-service increases the volume of care provided, but also that the level of payment seems to play a larger role than the method of payment. Results from "before-after" comparisons (sudden and exogenous change in payment method) show that the impact of the payment method strongly depends on the physician's environment, especially peer pressure. Another result is that payment by capitation increases the volume of drug prescriptions.

In the real world, methods of payment are seldom observed in pure form: most payers are seeking an optimal combination, based on the notion that the influence exerted by the physician depends on the type of care provided. A key innovation has been to introduce, in traditional methods of payment, corrective features at the margin targeting specific health outcomes, generally measured on a large population base (vaccination rate), or financial results. We refer to these practices as "performance payment." In the United Kingdom, for example, the portion of income that is independent of the level of services is 65 %, while fee-for-service payments represent 25 %, and performance payments 10 %.

Incentives linked to financial results are effective, particularly in decreasing hospitalisation rates, but they raise a conflict of interests that tends to lower the patient's level of confidence toward the physician and to alter the nature of the physician-patient interaction.

Today, payers prefer incentives linked to health outcomes, which is more compatible with medical ethics. In the United Kingdom, target payments seem to have a positive impact on vaccination or screening rates (simple observation "before-after"). Results from randomized studies are however contradictory: no impact on cancer detection among Medicaid clients, but a positive impact on the vaccination of Medicare clients or on quality indicators such as cesarean rates, length of hospital stays or certification rates for private-sector insured patients. Studies examining both the impact on costs and on quality are difficult to find.

Another innovation is to balance individual incentives with group incentives: under a fee-for-service payment regime, the unit value decreases as the collective volume increases. Applied to a an excessively large group of providers, this system raises a "free-rider" problem, where each individual provider increases his volume to compensate the reduction in price. In this case, controls over individual activity levels, or discounted rates are then necessary. Another solution is to reduce the size of the group targeted by incentives, on the model of the British Primary Care Groups, or the U.S. Medical Groups. The difficulty is to strike a proper balance between physicians' accountability for the group, and the financial and technical strength of the group, which suggests a minimum group size.

Finally, most group incentives rest on non-financial measures, such as the diffusion of best practices protocols, or peer-reviewed individual practices, even selective contracting based on commonly defined practices. However, the impact of these non-financial incentives has not yet been evaluated.

List of Abbreviations and Meaning

HMO:	Health Maintenance Organization
	Health plan with a limited panel of physicians (patient is not managed if he consults outside the panel)
MEDICAID:	U.S. public health insurance for the indigent
MEDICARE:	U.S. public health insurance for disabled persons and persons over 65
PCG/T:	Primary Care Group or Trust
	Group of general practitioners in the United Kingdom which is assigned an overall budget and manages all care for a given population
PPP:	Purchasing-power parity
	Unit for comparing expenditures between countries, with variability of exchange rates factored in
PPO:	Preferred Provider Organization
	Health plan with panel of recommended physicians (patient is only partially managed if he consults outside the panel)

General Question

How do payment mechanisms and incentives effect the utilization of health care services and their costs? To what extent can changes in policy, practice, and incentives change the cost structures and trajectories in health care?

Introduction

The efficiency of the health care system affects the public economy and economic policy because health spending is always at least mutualized, if not socialized. The question of efficiency has long been confined to controlling the rising costs of health care, but it is now being raised in a more complex fashion: how to reconcile reasonable spending with the requirement for quality and fairness.

This question has generated a great deal of economic literature, modelling the characteristics of the medical care market and the behaviours of producers and consumers of care in order to suggest optimum contracts to the regulator for satisfying these three contradictory objectives (expenditure containment, quality, fairness). This theoretical literature, focussed on latent behaviours within the payer/patient/physician triad, has given rise to unresolved empirical questions, particularly as regard the extent of the physician's influence over the patient.

Our interest here is in the segment of this literature that addresses the impact of the method of physician payment on the volume of services the physician provides or prescribes for the patient, the quality of those services, and inequalities of access to care. The method of paying the physician is a true strategic choice, and there is no "natural" mode of payment. Because the physician is subject to an obligation of means and not of outcome (for reasons of uncertainty), he is not in fact a classic producer who sells an outcome or end-product and takes the risk that this end-product may be worth less than its production cost. Besides, we are talking about the remuneration of physicians, which is what makes them factors of production, and not the retail price of medical services. And yet, the physician is not a mere factor of production, because his degree of autonomy in organizing the elementary actions that contribute to the production of his services is a component of the quality of the services provided.

After a brief presentation of the different methods of physician remuneration, Part 1 will summarize the economic literature on their impact on health care costs. We explain the theoretical issues behind the various payment mechanisms and examine the extent to which the empirical studies conducted in various national contexts confirm these theoretical postulates.

Economists hypothesize that, while the physician's profit is not the sole motive behind a medical decision, it is an element of it. This hypothesis is shared and supported by medical sociology, which shows that when the consequences of a medical decision for a patient's well-being are not clear, the trade-offs for the physician in terms of leisure, reputation or income take on greater importance. It is then no longer certain that the patient is receiving the exact amount of care that his treatment requires.

Economic analysis implicitly raises questions like : Given the motivations of physicians, what impact does the method of payment have on medical expenditure? Such an attitude does not mean that motives other than profit (professional standards, respect of peers, or the patient's interest) have no importance, but rather that we can hypothesize that payment methods have no impact on them. In reality, this hypothesis is certainly erroneous, and experiences of changing physicians' modes of payment can show us why the mechanisms adopted can depart significantly from economic recommendations, particularly because the payment method can interfere with these other motivations of the physician (Part 2).

The Various Mechanisms of Physician Payment

It is customary to distinguish three main methods of physician remuneration:

- Fee-for-service (FFS);
- Capitation, which is a lump-sum payment per patient managed for a given period of time; and
- Salary.

Different countries use one or another of these three forms of compensation for general practitioners (GPs). Specialists generally receive a fee-for-service or are on salary.

This traditional typology raises certain questions.

First of all, the overall remuneration of a physician can combine a number of methods of payment: these mixed or blended payments are the practice in some health care systems, as we shall see in Part 2.

Next, while it is convenient to oppose these three mechanisms, they can also be considered on a rising scale of inclusiveness, in which intermediate situations can also be imagined:

- At one extreme, the fee-for-service is the most specific and least inclusive form of payment for a medical service. Yet, it still constitutes a fixed price: when a consultation is paid at a flat rate, as in France for example, it makes no difference whether it is long or short, whether a clinical examination is performed or a prescription is simply renewed. And one notes that the degrees of inclusiveness of the nomenclatures used in different countries for pricing services vary, and that a comparison of those nomenclatures could be one way of describing different types of FFS.
- Capitation adds another level of inclusiveness, since the physician is paid the same amount for a patient regardless of the quantity of services provided. The physician's income varies only according to the number of patients taken.
- Salary is the all-inclusive extreme form of payment, where income does not change regardless of the physician's level of activity – in terms of number of patients in care or quantity of services provided per patient.

On this scale, one can imagine intermediate situations, for example, between fee-for-service and comprehensive capitation: a lump-sum payment per episode of care, or a lump-sum payment for monitoring a chronic pathology over a given period of time. A few experiments with these types of mechanisms will be described in Part 2.

In summary, even though the three "archetypal" methods of payment are traditionally opposed – a practice we shall adopt in our review of the economic literature below – there is no reason why intermediate methods cannot be devised.

Finally, as regard the forms of payment of health professionals, we are witnessing the emergence of mechanisms that do not fit any of the three models mentioned above, but are similar to results-sharing mechanisms, whether those results are financial in nature (cost containment) or target the quality of the medical service.

This type of mechanism, of which we provide examples in Part 2, might be considered a fourth mode of compensation, as an alternative to the three previous ones. That is, in fact, the approach taken by some authors who are now distinguishing between four methods, often labelling the fourth "target payments". In practice, however, this type of results-sharing is only complementary and peripheral to the main method of payment. It is thus difficult to consider it as an alternative – it is, rather, an adjunct to the three main methods of payment. In future, it could possibly become a greater factor in physicians' remuneration.

Part 1:
The Economic Literature

We present here a review of what the economic literature has to offer on the impact of the method of payment of physicians' services on the total health care budget.

The Facts and the Simple Theoretical Postulates

Based on aggregated data, a country's total health expenditure is affected by supply variables in general and the method of physician payment in particular. In 19 OECD countries, Gerdtham et al. (1992) find that, all other things being equal, "physician fee-for-service" (i.e. a variable indicating that this is the majority payment method in the country) increases health spending by 11%. A more recent study employing panel data (for 22 OECD countries between 1970 and 1991) no longer finds that FFS per se has any direct effect, but rather an indirect one: medical density increases expenditure when physicians are paid on a fee-per-service basis (Gerdtham et al. 1998). However, these relations observed on aggregate data are difficult to interpret, for it is possible that total national spending and specific institutional arrangements such as FFS are both positively correlated to a third variable, such as the fact that physicians practice in isolation.

The economic literature thus attempts to describe the micro-economic process by which the method of physician payment might have an influence on medical spending; to formalize this process, a payment method is characterized by its degree of inclusiveness. In the rest of this first part, we will focus on the opposition between systems of inclusive or lump-sum payment (capitation and salary) and fee-for-service schemes.

First, we can identify how payment methods are expected to impact on health care costs by isolating the other objectives of the health system (quality and fairness). To do so, let us briefly describe the physician's activities: to care for patients, the physician uses certain resources. Resources such as an office are necessary whether there are patients or not; others are used only if the are clients. In reality, the physician does not set his price himself: he receives it from a payer. The resources used in production are of two types: quantifiable material resources and non-material resources that are difficult to quantify. An example of the former would be the consumables of the medical practice; examples of the latter would be the time the physician devotes to each patient, his competence (a function of his continuing training, the effort he makes to keep up to date), his ability to listen to the patient, and his mental effort. In economics, the level of non-material resources is usually referred to as the "physician's effort". An important difference between material and non-material resources is that the payer can take the former into account in the payment scheme, whereas doing so for the latter is more difficult. It is difficult for a payer to compensate a resource when there is no proof that the resource was actually used.

With in hand this simplifying model, what then can be said about the methods of payment?

In fee-for-service, the price takes into account fixed costs and variable costs (if not, the physician refuses to work) and so is higher than the average cost of the variable resources alone: thus caring for an extra patient brings the physician a financial profit. If, in addition, the

physician has some power over the patient's demand, FFS creates favourable conditions for a larger quantity (and hence expenditure) of services than the patient may wish to receive, or than may have been medically necessary. Under this model – the physician has some power over the patient – if the payer reduces the unit price, the physician will respond by increasing quantity[1] to maintain his profit; this explains why a reduction in the price of care leads to an increase in the supply of services.

Under a capitation formula, on the other hand, the physician is not reimbursed proportionally to the resources committed, and so has no interest in multiplying his services, since he would then lose money or waste efforts. He prefers to treat the patient using the least possible amount of resources to achieve a given level of quality.

The Cost-Quality-Fairness Trade-off: Status of the Problem

If the question were limited to cost containment, one might wonder why all regulators have not opted for some form of lump-sum payment. Obviously, there are historical reasons that support fee-for-service in spite of the evident superiority of the lump-sum payment as an instrument of budget control (see, for example, Emery, Auld and Lu 1999). However, in the culturally homogenous United States, one notes that different payers have adopted different arrangements: some prefer a form of capitation, while others prefer FFS; the latter are surviving, and even seem to be recapturing market share lately.

So there are certainly reasons of cost-effectiveness that also explain why the lump-sum payment method is not universally adopted:

- An initial reason is related to the quality of the medical service provided: while lump sum payments offer a structural means of resolving the problem of increased volumes of services delivered by physicians, it raises the risk that the physician will provide too few services (consultations, examinations) and too few non-material resources (shorter consultations, less attention) to the patient. Of course, the regulator can impose a minimum level of services per patient, but it will be difficult to control the level of non-material resources. If the physician is paid to manage a patient and is not sanctioned in any way,[2] he has an incentive to collect the lump sum payment and not provide the corresponding services and effort. The economic literature tries to shed light on this point and to define the circumstances where the lump sum payment method can jeopardize medical quality. More generally, lump sum payments can be seen as a delegation to the physician of responsibility for the optimum organization of services that are factored into health care, whereas with fee-for-service payment, this role is shared between physician and regulator. Where there are multiple payers, FFS raises an additional problem of inconsistency among pricing regimes, but to our knowledge this problem has been studied only for hospital services (Tai-Seale, Rice and Stearns 1998).
- This quality problem can also have consequences for spending: the physician is not only a producer of services, he is also a prescriber. Capitation is generally accompanied by a referral responsibility for the primary care physician (PCP): he makes decisions concerning quantities of analyses, medications and specialized or hospital consultations. If the physician reduces the intensity of his effort because he is paid in a lump sum fashion, even as he

remains concerned for his patient's health, he can very easily generate a high volume of health care costs by increasing his prescription rate.

- Finally there is the issue of universal access to care. The lump sum formula always entails a financial risk for the physician: if doctors are averse to uncertainty, they will refuse to take patients who incur highly variable *ex ante* costs. If doctors have better selection skills than payers, they will make money by treating individuals paying a high lump sum and refusing to provide care to others (e.g. see Mulligan 2002).

Ultimately, the question is then: what form of payment can best reconcile the objectives of expenditure control, quality of medical service and universality of access to care? We will first look at the theoretical models that explain the physician's discretionary power over the patient's consumption, models which conflict on the potential ability of the physician to "induce" patient demand (Evans 1974). This ability has some important consequences for our study, for it increases the risk of lump-sum payments leading to a reduction in the medical services received by patients. This discussion concludes with an analysis of the physician's behaviour as a prescriber of medical services that he does not provide himself.

The Cost-Quality-Fairness Trade-off: Discretionary Power of the Physician

Theoretical approach

We saw earlier that the physician will profit from fee-for-service if he is able to impose on the patient more services than the latter wants or needs. How is this made possible?

There seems to be broad agreement that, in interacting with his patients, a physician does indeed have a superiority that allows him to influence the consumption of his services.

One reason for the physician's superiority is that he has a knowledge advantage over his patient. There is abundant theoretical literature debating the fact that superior knowledge is sufficient for an expert to impose an agency relationship, that is, a relationship in which the lay person puts himself entirely in the expert's hands. This literature concludes that in a competitive context among experts, if the lay person can get a fairly accurate idea of the link between the expert's effort and his results, then superiority of knowledge is not enough to establish an agency relationship. The expert is selling so-called "experience" goods, the quality of which will ultimately be determined by the buyer. On the other hand, if some fundamental uncertainty prevents the buyer from forming a notion of how the expert's effort impacts upon the result he obtains, then an agency relationship can exist. The expert is then selling "confidence" goods, as the lay buyer has to have absolute trust in him.

What about medical goods? Rice (1993) advances the radical idea that there simply is no such thing as informed and independent demand for care on the part of the patient. He bases his argument on the fact that, according to the findings of Rand researchers, the additional care obtained by the best-insured patients is not, in the view of independent experts, really appropriate given their health status.

The idea that there is no independent patient demand for care is no doubt excessive (we all make health decisions independently of our physicians), but on the other hand, it is true that part of the medical services provided by the physician is not observable. This difficulty in assessing the medical services provided is undoubtedly one of the reasons why physicians in developed countries are not generally authorized to own pharmacies or sell medications: if they could increase their earnings in this way, they might abuse their expert's position by persuading patients that it is in their interest to consume drugs.

One can also make a few *a priori* predictions. For example, it is certainly more difficult to observe the quality of a specialist's services whom we rarely see: to resolve the asymmetry of information, the regulator will prefer to have the quality of this specialist's services observed by another physician through referral[3] by a primary care physician. However, empirical proof of a degree of inducement on the part of physicians is very difficult to establish: even if it is determined that different treatments were provided by two doctors to two identical patients, and that a connection in found between this variation in practice and the economic interest of the physician, it is still necessary to ascertain whether the variation is not perceived by the patient as a deterioration of services received.

In fact, the agency relationship assumes not only that the physician imposes his views on the patient, but also that the patient does not realize it (he trusts the expert). As McGuire (2000) demonstrates, however, one can easily imagine a physician imposing his views even if the patient realizes that the physician is not doing exactly what the patient wants, or what the physician would do for himself. In technical terms, an agency relationship is not necessary for the physician to hold some discretionary power over the patient: it is enough for the physician to be in a situation of imperfect competition with patients for the latter to accept from a service delivery that is not totally satisfactory.

One good reason explaining this imperfect competition between physician and patient is the latter's attachment to certain characteristics of his doctor, which results in the patient not seeking out another doctor. The patient's attachment for "his" doctor (family doctor, the usual source of care) is abundantly documented, and is explained by the fact that long-term familiarity allows the physician to specialize in the patient. Obviously, this attachment of the patient to his doctor applies more to the GP (or primary care physician) or chronic care specialist.

As a result of this attachment, physicians are not perfect substitutes for each other: each doctor more or less has a free hand with his patient and can impose different choices upon him than those the patient would spontaneously select if he were able to replace his physician with no adverse effects. In economic terms, having this freedom translates into "having market power" and behaving like a monopoly. The physician is precisely in a situation of monopolistic competition with his patient: like a monopoly, the physician can take optimum advantage of his patient's willingness to pay by playing on prices and quantities (whereas in a situation of perfect competition, there is only one price, that of the marketplace); but for all that, if the physician goes too far (strays too much from his patient's expectations or needs), the patient can leave him for another doctor.

Attachment and agency can even be said to complement each other in the way they operate: when the patient sees the doctor only rarely, he has little attachment to him, but also has more chance of being in an agency relationship and having to bestow blind trust; on the other hand, when the patient is in a long-term relationship with his doctor, it is easier for him to observe the quality of services received, but more difficult to act in a competitive manner and oppose services that leave him dissatisfied.

What impact might the nature of this discretionary power of the physician have on the problem that concerns us here? Schematically, the closer one gets to a situation of monopolistic competition, the more the physician has to take into account the risk of the patient's departure: with fee-for-service, that threat limits the physician's power to provide too many services the patient does not want; with capitation, it limits the physician's power to excessively reduce his volume of services, and above all the effort he devotes to his patient. If an individual's attachment to a given doctor is a constant variable, the physician arbitrates between the length of his client roster and the benefit he derives from each client listed on it. The physician is then said to influence the patient's consumption.

On the other hand, the closer we get to an agency relationship, the less likely the patient is to pose a threat of departure for the physician, who can provide too many services if they are paid on a per-service basis, or not enough effort if he is receiving a lump-sum payment. In this case, the physician is said to induce demand.

A large body of literature attempts to prove empirically, in an indirect way, that the physician has absolute discretionary power, since the patient is not in control. A classic test is to measure the response of physicians to a variation in medical density in a FFS context. Remember that, in the case of inducement, the physician has no competition: if medical density increases, the physician will have on average a lower number of patients (where inducement is involved, the quality of the physician has little impact on his attractiveness, for he is not in competition) and so will react to preserve his income by increasing the volume of services used by his patients. But in a context of monopolistic competition, higher medical density raises the risk of the patient leaving the physician (a break being less costly to the patient), so the physician will not create a wider gap between the consumption wanted by the patient and the services provided.

Apart from the empirical issues (the truly exogenous nature of the increase in density, the difficulty of observing major variations), this test is not perfect; it is based on the arguable hypothesis that, in monopolistic competition, an increase in medical density facilitates the departure of unhappy patients; in fact, if a patient's attachment is due to personal characteristics of the physician that are not affected by medical density, one can find an increase in services following an increase in medical density in a context of influence. Pauly and Satterthwaite (1981) raise a similar objection: a higher density of physicians increases the capacity of each physician to influence demand via a process of medicalization of public expectations.

Overall, it does not seem possible to decide on the degree of inducement on the basis of measurements of physician activity. Direct surveys of patients' level of satisfaction and their motives for choosing or leaving a physician would doubtless be of great interest. But it must be acknowledged that there has been no measurement of the degree of inducement based on such

direct statements by patients. An invaluable indication is provided by the fact that, in the United States, the sickest persons insured by Medicare prefer to remain in FFS plans and retain the freedom to access the physician of their choice instead of opting for the more extensive coverage proposed by HMOs. This is reason to suspect that the physician's latitude to persuade the patient that what he needs is precisely what will maximize the physician's income may increase with the patient's degree of morbidity.

Empirical approaches

Faced with varying medical practices, it is impossible to know beforehand whether a given practice is excessive or whether another is restrictive. Practices can be compared after the fact to some technical standard, such as a recommendation, or to a statistical norm, such as an average practice, but there is nothing to validate such comparisons.

Hence we can only measure the impact of the method of physician payment on the volume of services consumed by the patient, quality and universality of access; but nothing can be said on the proper mode of payment based of such studies. To measure this impact, researchers look for comparisons where all other things are held equal except the payment method. Scott and Hall (1995) have found seven empirical studies published in English on this theme, noting that this small number is linked to the fact that these are "opportunistic" studies which make use of data compiled for other purposes. Gosden et al. (2001) list another similar study.

For comparisons to be meaningful we must first be sure that the contexts are comparable: comparing the impact of different compensation systems in areas that are far removed from each other geographically or socially does not make much sense. Therefore, one must find homogeneous contexts with sufficient variability of payment methods. A second problem with this type of comparison is that it is difficult to ensure that all things apart from the payment method are in fact equal: the fact that a patient chooses a physician who is paid on a per-service basis or by capitation can be correlated with some unobservable characteristics that are themselves related to the use of the health care system. Similarly, physicians can specialize by type of contract (Glied 1998), again for reasons not unrelated to their work methods and the volume of services they provide. Finally, it is difficult to be sure that the level of payment is the same from one method to the next, and that one is not measuring the combined effect of a difference in payment method and level.

Hickson et al. (1987) conducted an experiment controlling for the first two problems: 15 pediatricians, members of the same clinic, were randomly allocated a mode of payment (salary or fee-for-service). The study compares the volume of preventive visits to physicians on salary and those paid on a per-service basis: with controlled observable characteristics of physicians and patients, the pediatricians paid on a per-service basis delivered significantly more visits.

This additional volume also reflects an ambiguous variation in quality: patients treated by physicians paid per service say they receive better follow-up, but the volume of preventive visits suggested by these physicians departs more from the recommendations of the American Academy of Pediatrics than the volume observed for salaried physicians. According to

Gosden et al. (2001), this average difference between salaried physicians and those paid on a per-service basis involves two different phenomena: visits in excess of the recommended number are fewer for patients of salaried physicians than for those of FFS physicians, but the recommended visits missed by the former are more numerous than those missed by the latter.

Another study with physicians randomly assigned to payment methods is that of Davidson et al. (1992), on 80 physicians treating children under the U.S. Medicaid program. The study monitors three groups: a control group, paid on a per-service basis; a fee-for-service group receiving higher rates; and a group paid by capitation. The volume of primary care sessions increased for the two tests groups, underscoring the impact of the level of remuneration regardless of payment method. However it increases more in the FFS group (+0.8-0.9) than in the capitation group (+0.5-0.6).

The price to be paid for these methodological gains (random assignment of physicians to payment methods) is obviously the sample weakness and results that cannot be easily generalized.

We therefore turn to some "before/after" comparisons, in which a payer changes the payment method of a single group of physicians and patients. In this case, we can assume a real exogenous change in payment method and observe its effect free of any bias. Furthermore, in implementing reforms, efforts are made to maintain physicians' income at a constant a level, so the effect of payment method can be measured separately from the level effect.

An initial study of this type was done by Stearns et al. (1992). It reached the conclusion that capitation has a weak impact on volume of services provided: in a health plan for Wisconsin government employees, PCPs moved from fee-for-service to individual capitation. At the same time, the unit price of specialists' services were greatly reduced. Paradoxically, there was an increase in the number of ambulatory visits, but it was visits to specialists that increased, and there is reason to believe that specialists increased their self-referral to compensate for the drop in service rates. The volume of visits to GPs remained unchanged, so the transition to capitation had no effect. It is possible however that the experiment was disrupted by another factor: at the same time, the GPs were allowed to share in the profits from reduced hospital expenditures. It is thus possible that they were motivated by this profit-sharing and stepped up their effort in primary care medicine in order to limit hospitalizations. The study in fact shows a perceptible drop in the hospitalization rate (though not in the length of stay). This study is not completely free of bias, because certain primary care physicians opted out of the plan, or refused plan patients (or certain services). Some patients may also have left the plan, for in addition to the change in physician remuneration, there was a transition to an exclusive HMO approach (an insured person is not managed if she consults outside the panel), whereas the plan previously functioned as a PPO (reduced management of an insured person who consults outside the panel).

An experiment offering better control of these voluntary separations was conducted in Denmark (Krasnik 1990). General practitioners in the city of Copenhagen moved from pure capitation to mixed capitation and FFS, while regional/county physicians remained under capitation. The author was thus able to compare changes in volumes in the "test" group

(the Copenhagen GPs) and the "control" group. There was a significant increase in the volume of services provided by the physicians in the test group with the transition to fee-for-service.

This effect is not universal, however, and the Norwegian experience seems less conclusive on the impact of fee-for-service. Using records of contacts by patient and by physician[4] for Norway, Kristiansen and Holtedahl (1993) show that FFS increases the volume of home visits, all other things equal (although the patients' state of health was unknown), but that the effect of the payment method is weak compared with the influence of a patient's individual characteristics: the physician remains more motivated by health concerns than by his income.[5] This precedence of the clinical over the economic in Norway seems to be confirmed by Grytten and Sorensen (2001), who show that physicians paid on a per-service basis do not perform more examinations than salaried physicians, even when one controls for factors that lead physicians to choose a given type of contract. The authors claim that this primacy of clinical concerns is mainly due to strong peer control in Norway, which prevents the physician from taking advantage of his position of superiority over the patient.

In addition to the damage caused in terms of average quality, inducement can also be damaging to the fairness of the system. Vulnerable segments of populations (children, seniors, the mentally ill, the poor, linguistic minorities) have more difficulty observing and tracking the quality of the physician's service, so it is tempting for the physician to use this ability to induce demand primarily on members of these groups. It is noteworthy that HMOs ration clinical quality for these groups, while leaving average quality unchanged (Miller and Luft 1997).

The Cost-Quality-Fairness Trade-off: The Physician's Capacity to Increase Prescriptions

Referrals and prescriptions are important components of the physician's practice and of total health care costs. In France, 33% of visits to a physician are the result of a recommendation from another physician. In the United Kingdom, 5% of PCP visits lead to a referral (Coulter, 1992), and there is a very large variation in physicians' practices which cannot be explained by patient traits (summarized by Scott 2000).

A simple but sound theory of physician behaviour is that payment via capitation or salary encourages the physician to transfer his own work to others and increase the volume of prescriptions so as to cut down on unremunerated effort (time spent with the patient, listening, auscultation).

This prediction has wide empirical confirmation. The study by Krasnik et al. (1990) shows that when GPs changed to FFS, their rates of referral and prescription dropped substantially. This study uses a control sample whose payment method remained unchanged over the same period.

International comparisons suggest that less time is spent in consultation when payment is by capitation: according to Sandier (1990), while the French GP, paid per service, devoted an average of 15 minutes (in 1979) to each consultation, the English GP, paid by capitation, was content with 8 minutes (in 1987). However, in a homogenous context and using individual data,

there is no confirmation that capitation or salary reduces consultation time: Kristiansen and Mooney (1993), using Norwegian data, even find that GPs paid per service spend less time in consultation than those on salary, although the difference is not significant.

One way to prevent capitation from raising the cost of prescribed care is to make the prescriber responsible for a patient's total care budget. This is a form of vertical integration of care, assigned to the primary care physician; we will outline it below.

Part 2:
In Search of the Optimum Method of Payment: Lessons from a Variety of Experiences

The question of incentives associated with payment methods has received growing attention since health care systems have been faced with major issues of balancing cost, quality and fairness. Through general reforms or local experiments, various solutions have been tried in an attempt to reconcile these potentially contradictory objectives by means of the methods of compensating professionals. These solutions will be reviewed in this part, distinguishing between a number of approaches.

One approach tries to combine various incentives within individual physician remuneration, using blended payment systems that include lump sum, capitation and fee-for-service. Specific financial incentives may be incorporated into these, the most innovative being mechanisms for sharing in financial or health outcomes (performance-based payment).

A second approach deals with different financial incentive systems at the individual and collective levels of the medical profession.

The conflicts of interests resulting from this second approach are such that it lends itself more to smaller, rather than very large groups of professionals; this has led to a third approach, that of making physicians' groups responsible for reconciling financial and quality objectives.

A final approach to the best cost-quality ratio is to combine financial incentives with incentives of other kinds, such as information provided to the physician, formulation of practice benchmarks, and different tools for their dissemination. The collegial dimension of the medical profession can facilitate change in practices, and this affords a means of potentially gaining the interest of the groups or networks mentioned above.

Incentive Combinations within Individual Physician Remuneration

Before turning to mixed payment systems, it should be noted that no method of payment has emerged as an overall alternative to the standard three: fee-for-service, capitation and salary.

Episode-of-care payment, transposed from hospital payment to diagnostic-related groupings (DRG), was considered by Medicare in the United States in the mid-1980s, but seems to have had few concrete applications in ambulatory medicine. It can be envisaged for technical care in acute episodes, e.g. a surgeon receiving comprehensive remuneration for pre-op, surgery and post-op (Robinson 2001), and it has been studied in cardiology, e.g. for coronary bypasses (Showstack, Garnick and Rosenfeld 1987). But extending this mode of payment to all medical activities raises numerous technical problems.

In terms of practical applications, therefore, innovation and inventiveness have mainly developed around the manner of organizing different elements of payment and using marginal incentives for a minor percentage of remuneration.

One interesting example of mixed payment is that provided to British general practitioners, whose compensation includes (Redbook 2002):

- A basic allowance to cover a fraction of operating costs, in the form of a sliding lump sum per patient based on the number of patients. An additional allowance offsets extra costs of practising in a rural area. Top-ups are also paid based on the physician's experience ("seniority" fees).
- A capitation per patient on the GP's roster, with three levels according to age (under 65, 65 to 74, and 75 and over); patients in disadvantaged areas also give rise to an additional capitation reflecting their greater needs.
- FFS for night visits, vaccinations, emergency consultations for colleagues' patients, minor surgery, as well as more comprehensive specific fees for monitoring contraception, child health and maternity medical services.
- Target payments for cervical cancer screening (payment depends on the rate of women who have had a smear in the previous five years) and for immunization of two-year-old and pre-school children.

The portion independent of level of service makes up 65% (50% for capitation and 15% for basic allowances), FFS accounts for 25% and target payments for 10%. In addition, U.K. physicians working in poorly served rural areas can dispense medications to their patients and receive specific fees for this service.

Have incentive payments had the results expected? In fact, it appears that activities paid on a per-service basis have increased most of the time, though not always (for example the proportion of physicians agreeing to monitor pregnancies to term decreased from 1960 to 1980). In any case, it is not possible to apportion within this increased activity the role of financial incentives and that of other factors related to the general evolution of professional practices and patient demand (Whynes and Baines 1998).

While in the National Health Service (NHS) certain productivity incentives have been added to what were originally lump-sum payments, we are now seeing the introduction of packages or lump sums into FFS systems, for example:

- In Quebec, for hospital specialists, mixed remuneration has taken the form of introducing a lump-sum portion, and in return paying for specific services at a fraction of their rate and eliminating billing for related services.
- In France, GPs who volunteer to be "referring physicians" receive an annual lump sum of 46 Euros for general patient monitoring, in addition to billing per service (although this option has been chosen by only 10% of GPs and 1% of patients).

The most innovative forms of blended payments incorporate elements of sharing in the outcomes (target payment). Those outcomes can relate to health matters (as in the British example above), but they can also be financial, i.e. associated with cost control. Such incentives are used by "managed care" organizations in the United States to reduce specialist referrals and use of hospitals. They are generally based on a formula that gives the physician an interest in the organization's financial performance. What assessment can be made of such outcome-sharing experiments?

Interest in Financial Outcomes

The 1991 reform in the United Kingdom ("fundholding") gave British general practitioners a financial interest in medication and programmed surgery expenditures for patients on their roster: the volunteer GP was assigned a budget at the start of a period for all his patients and could retain any year-end surpluses. Theoretically, such surpluses are not income, since the GP has to reinvest them in his practice, but in reality it is difficult to separate the physician's personal income from the revenue of his practice. Evaluation of this experiment has shown that physicians did indeed realize savings on their medication budgets, but not much on programmed surgery, one of the reasons for this being the quasi-monopoly held by British hospitals (Coulter 1995).

A study by Debrock and Arnould (1992) measured the effect of financial incentives to the physician by controlling for existing group incentives. Their conclusions for the 35 Illinois managed care organizations studied between 1985 and 1987 were that individual financial incentives reduced the hospital admission rate by 16% and cut the number of consultations per client by half.

While giving physicians an interest in limiting expenditures seems an effective tactic, the conflict of interests it can raise between professional ethics and the financial interest of the practitioner is negatively perceived by the profession, and above all by the general public:

- A survey of 766 U.S. physicians, 58% of whom were subject to group or individual incentives, showed that 57% of practitioners felt pressure to limit referrals and 17% thought that this could negatively affect the quality of care management (Grumbach, Osmond, Vranizan 1998, quoted by Armour, Pitts, Maclean et al. 2001). This survey also gives an idea of the magnitude of such bonuses: according to the physicians surveyed, the bonus accounts for about 7% of their median income.
- Although not particularly sizeable, these financial incentives are raising concerns among patients, who fear that they may limit the professional autonomy of their physician. There are few empirical indications of the extent of this concern, apart from many legal actions concerning financial incentives of physicians. In 1996, U.S. legislation set certain limits on contracts between managed care organizations and physicians and made their publication mandatory. According to Hall, Dugan, Balkrishnan et al. (2002), the publication of incentives has the effect of slightly increasing patient confidence if the physician is paid by capitation, but has no effect if he is paid per service.

Many authors, insurers and HMOs now think that performance incentives must be used to improve quality by focussing on health as opposed to financial objectives. According to Rosser and Kasperski (2002), Ontario physicians say they are in favour of a transition to capitation provided that it is mitigated by fees for certain services such as being on call, and by premiums for attaining prevention objectives.

Interest in Health Outcomes

This does not directly concern health objectives – a seductive but not very practicable idea – but rather the management of the population concerned. Prevention, both primary (immunization) and secondary (screening), is its most frequent domain of application.

The example from the U.K. cited above seems to show that these "target payments" have a positive impact: according to the British Department of Health (quoted by Scott and Hall 1995), the proportion of GPs reaching the objective set rose in five months, for vaccination, from 55% to 70% (objective: a vaccination rate of 90% or 70%) and for smears, from 53% to 67% (objective: for 80% of women from 25 to 64 to have a smear within five years). Of course, this simple observation of before/after results cannot control for other possible explanations and categorically claim that the increase is due to financial incentive. That is the point made by Armour et al. (2001) regarding another experiment in Northern Ireland, involving childhood immunization: there again, while there was a substantial increase in the vaccination rate during this period, the pure effect of this measure is not distinguished from other concomitant effects.

A bonus experiment to improve cancer screening, set up by a managed care organization for people on Medicaid, has been evaluated (Hillman, Ripley, Goldfard 1998). A six-month bonus ranging from 10 to 20% of capitation for all female clients was paid to the six medical practices achieving the highest screening rate. Fifty-two practices were randomly assigned to an intervention group (with incentives) or a control group. The study revealed no significant difference in screening rates between the two groups.

However, positive conclusions were drawn from an incentive experiment for flu vaccination for people over age 65 involving 54 New York practices, which was evaluated via a controlled test (Kouides, Benett and Lewis 1998). In addition to remuneration for the vaccine ($8), the physicians received $0.80 per vaccine beyond a vaccination rate of 70% for persons 65 years of age and over and $1.60 for a rate over 80%. The immunization rate in the group receiving the bonus (69%) was six points higher than that of the control group, and 52% of the practices receiving the bonus had an immunization rate of 70%, versus 44% in the control group. An analysis controlling for a number of environmental factors suggests to the authors that the introduction of bonuses served to boost the immunization rate of the elderly by 7%.

A recent trend seems to be to tie the bonus to various quality indicators. In one experiment done by Aetna (Hanchak 1997), groups of contracting physicians received bonuses based on their score on a quality-of-care index incorporating a number of aspects, including patient satisfaction, appropriateness of treatment, and efficiency. The authors concluded that there was a positive impact on all aspects of quality (2% decline in the cesarean rate, 25% decline in average

length of hospital stay, 85% increase in biopsies, and a certification rate approaching 95% at the end of the program) except patient satisfaction, which does not seem to have improved.

Armour, Pitts, Maclean et al. (2001) conclude from a review of the literature that the impacts of incentives are contradictory, and do not allow for any easy final verdict. They also note that studies rarely deal with volume effects and quality effects at the same time, and in this they see a recognition of some kind of trade-off between cost containment and quality.

Different Incentive Combinations at the Individual and Group Levels

A second approach is to attempt, not to counterbalance different incentives within individual remuneration, but to offset individual incentives with collective incentives.

This is illustrated, for example, in the limiting overall envelope systems associated with FFS. Germany opted for such a system in the early 1980s, and other countries or regions have adapted the same principle, using varying methods suited to their own context.

German physicians are paid per service but are bound by collective moderation: fees-for-service for all physicians in a Land are capped, and the amount is distributed among practitioners by the physicians' unions proportionally to the activity of each, expressed in points on a list of services. In other words, the unit value of the point is not known in advance, but is estimated after the fact by dividing the total envelope by the accumulated number of points of all physicians (Busse 2000).

The direct remuneration of practitioners through the funds in the form of a cumulative payment for a given period (in Germany, per quarter) affects the operational nature of such a system. However, certain systems in which these conditions are not met have also introduced expenditure caps (Quebec, France, the United States for Medicare): the difference is that the unit rate cannot be automatically adjusted in real time, but must be decided – and negotiated – for the following year, based on actual outcomes. Obviously, this method is likely to be less effective in terms of strict adherence to the budget envelope.

In theory, this type of mechanism leads to a conflict, for each physician, between the collective interest in moderating volumes (therefore achieving a higher point value and a level of income that is unchanged overall with a lower output of work) and the individual interest which continues to be to maximize one's own volume of activity at a given unit price. Hence, it encourages "opportunistic" behaviours, with each physician thinking that he will be able to profit personally from collective moderation if he raises his volume of activity, something which ultimately leads to inflated volumes, contrary to the target objective.

Clearly, this is related to the dilution of responsibility within a very large collective. Each physician on his own has no chance of affecting the unit value through virtuous behaviour; on the contrary, he has every interest in being this "opportunistic" element in the great anonymous collective. We shall return to the question of the size of physicians' groups later.

The theoretical postulates of systems of this type – ongoing inflation of volumes and a correlative decline in unit prices – seem indeed to be confirmed by the observations in Germany (even though one can debate the proportion of the increased volumes that is to be attributed to opportunistic physician behaviour or to other factors: demand, technological progress, etc.).

So a complementary mechanism is needed to offset this incentive to individual behaviours that are too production-oriented. That mechanism can include:

- Control: this is the case in Germany, where individual activity is examined by the fund physicians. Incidentally, one might think that this control will be more effective as it is organized by the profession itself; but its feasibility depends on the profession's availability to co-manage financial constraints with the regulators, as demonstrated *a contrario* by the French example.
- Incentive: as in Quebec, with sliding-scale rates beyond a threshold of service volume; this has the effect of curtailing intensive activities.

The Physicians' Group as Locus for Integrating Clinical and Economic Objectives

In different countries we seem to be witnessing convergence toward a more collective practice of medicine, in various forms – networks, single-discipline or multidisciplinary groups.

Since the mid-1990s, this trend has emerged in such different national contexts as the British NHS and American "managed care" (Bocognano, Couffinhal, Grignon et al. 1998). In England, the 1997 reform instituting the Primary Care Groups or Trusts (PCG/Ts) made the first spontaneous associations of fundholder GPs a general fact of life; in the more competitive local contexts of the United States, physician groups have developed very rapidly to contract with health insurers seeking to build networks, and in extreme cases even to incorporate the insurer's functions themselves.

In both cases, the approach is to make these groups into highly structured networks with their own management infrastructure.

These groups are sometimes given financial responsibility and delegated management. For example, the British PCTs are remunerated via comprehensive payments, on condition that they distribute this funding among their various constituent medical practices. Following up on the "fundholder" experiment, budgets allocated include not only physicians' compensation but prescription and hospitalization budgets.

The PCTs are thus at once responsible for meeting an overall budget, making decisions between different components of that budget, and distributing fees and prescription budgets among their members.

To this end, they have to develop an expertise that allows them to optimize their utilization of resources. For example, in the area of drug prescription, all PCTs monitor their members' prescriptions by means of trend charts provided by the national level, almost all of them have a pharmaceutical consultant, 70% use common prescription reference systems, and 49% have produced their own formulary (Wilkin, Gillam and Coleman, 2001).

This example illustrates that the interest of physicians' groups lies in the ability to link financial accountability to clinical governance in a collective that is:

- managed by professionals, and so has both the technical competence to make the best decisions and a quality code of ethics;
- large enough to acquire a number of expert and assessment tools, but at the same time small enough to make each professional feel involved.

The enthusiasm for physicians' groups, considered to be in the best position to implement efficient management of care processes, and thus to reconcile quality of care with economic use of resources, has also been very strong in U.S. managed care programs. In the most competitive areas, the second half of the nineties saw very fast development of such medical groups and their management and bargaining skills, both with insurers upstream and hospitals downstream.

Within these networks, specific specialty groups can be assigned overall budgets, with the task of distributing them among the individual practitioners they manage. Practitioners can be paid per service, but the group sets up procedures (e.g. peer review, verification of the usefulness of care) which are more operational within a single specialty than in multidisciplinary settings (Robinson 2001). Within this framework, capitation mechanisms called "contact capitation" can be implemented – a fairly innovative approach for some specialists: once a patient is referred by a GP to a group physician, the latter receives a capitation for a period of 12 months, during which time he manages the patient as he sees fit.

This principle of compensation is more adapted to specialties whose activity is relatively homogenous (cardiology, gastro-enterology, etc.). It can be adjusted to account for the gravity of cases, e.g. by balancing patient numbers for certain diagnoses or services, or by allowing FFS for certain procedures (Franck 1999). This payment method has been used in numerous HMOs, and managed care specialists recently predicted that it has a promising future (Carlson 1997). The Swedish experience seems to confirm that group incentives can have a strong impact, even if individual income is not affected by the change in mode of payment: some hospitals moved to one payment per pathology, while others stayed with the fixed annual envelope, but in both cases the physicians were salaried hospital staff. The result is that hospital physicians paid per pathology significantly reduced lengths of stay, even though total cost in these hospitals did not decrease (Forsberg, Axelsson and Arnetz 2001).

The experiences described above entail very formalized networks with substantial delegation of responsibility. But the idea of promoting a more collective practice of medicine in the form of networks or groups is also developing in other systems, in a less structured fashion (France, Germany, some Canadian provinces with experimentations of family physician groups). Here the objective is rather to improve the coordination and continuity of care, something that an isolated

FFS exercise does not spontaneously encourage. But the underlying idea is the same – that between the isolated physician and the profession as a whole, the locally established group of physicians, sharing skills and a common culture, can be a tool for changing practices in the desired direction.

However, recent developments in the United States seem to reflect upon the excesses of this trend. California, where the medical group reigns supreme, has experienced many bankruptcies in recent years, and is now seeing its groups unravel, with individual contracting picking up momentum. The decline of the groups is happening in tandem with the decline of capitation as a method of payment (Managed Care Outlook 2001): the percentage of groups with at least one capitation contract, which rose from 1998 to 1999 (66% to 72%), fell in 2000 (55%).

The factors behind the fragility of the groups and their lack of staying power (diseconomies of scale, difficulty of incorporating insurance perspectives, demand for free choice of patients, etc.) aptly illustrate that the reconciliation of cost containment and quality objectives through the virtue of collective "clinical governance" has its limits, and that the context of extreme financial accountability is perhaps not the most conducive to making the best use of these collective organizations which, in spite of everything, seem to be the way forward in many systems.

Non-financial incentives

If physicians' groups can coordinate cost containment and quality of care, it does not simply rests on the alchemy of group and individual financial incentives: it is because the latter are associated with other incentive mechanisms.

These are of several types. The first is the **development and distribution of clinical protocols and recommendations,** found today in most public or private systems. These can be national or local, and may provide guidance or be mandatory (e.g. medication formularies). There is abundant literature on the comparative efficacy of different methods of disseminating references (training, interviews, computerized reminders) for their implementation by physicians, following the recommendations of the Cochrane Collaboration on Effective Professional Practice. It is beyond our purview here to reproduce and comment on this literature, but we can highlight its main lessons, as summarized by Durieux (1999): no studies have found that distribution of standards via print material or ongoing medical training has a significant impact; however, distribution by opinion leaders or, better yet, by visits from colleagues, does have a significant impact on physicians' practices.

Consistent with this finding, the **evaluation of individual practice**, particularly in terms of these reference sources, or compared with colleagues (release of information to the physician, peer review, etc.) is a tool for changing individual behaviours.

The care network or physicians' group is a preferred forum for applying these incentives, for the reasons given above. This is especially true since these networks select their members based on their support for the group's values – clinical, economic and cultural. A further step can be taken in multiple-insurer systems with **selective contracting** (where the payer is able to manage only a limited number of professionals), which is obviously a powerful non-financial incentive.

Conclusion: What are the Lessons for the Canadian Context?

Canada ranked fifth among OECD countries in 1998 for health spending as a percentage of GDP, and the interim report of the Commission on the Future of Health Care in Canada notes that the problem lies more with the unstable evolution of these expenditures than with their absolute level (OECD 2001; Commission 2002).

Also in 1998, per capita ambulatory care expenditures put Canada in seventh place, with a level ($PPP 333) representing a third of that in the United States and 80% of the German level, but 40% higher than the French level. The price trend for physician services in Canada over the 1985-1996 decade matches that of other OECD countries (excluding the United States), and the increase in volumes, which was quite high at the outset compared to other countries, seems to have been curbed from 1995 onward.

So Canada does not appear to have a serious problem of controlling health care costs.[6] However, the Commission's interim report underscores Canadians' great dissatisfaction with the accessibility and quality of their health care system.

To resolve these problems, must fee-for-service necessarily be called into question? We have seen that payment by capitation can pose a risk for quality of care and accessibility, particularly since the physician need not fear competition, should there be a shortage of doctors, for example. On the other hand, by modulating the physician's compensation according to the type of population served, capitation can be a means of addressing specific problems such as the uneven geographic distribution of physicians.

The current debate on the future of the Canadian health care system certainly provides an opportunity for discussing payment methods. Especially since the latest survey by the Canadian Medical Association reveals that, although 62% of Canadian doctors derive almost all of their income from fee-for-service, only 37% prefer that method of payment to other alternatives (Martin 2000).

Specific questions

What is the impact of physician payment mechanisms on both utilization of physician services, and overall health care utilization and costs?

How does fee-for-service payment for physicians influence utilization and costs compared to other mechanisms, and where are the observed differences?

There is no real alternative to the canonical payment systems of fee-for-service, capitation and salary. Recent innovations are more in the nature of marginal adaptations. Current knowledge of the impact of payment methods on health care costs is summarized, according to their degree of inclusiveness: fee-for-service allows the physician to increase the volume of medical services provided to the patient, and so limits the scope of modes of regulating by unit prices.

Conversely, lump-sum forms of payment (capitation and salary) limit volumes, but can adversely affect the quality of care provided, limit access to care for vulnerable populations and have unexpected consequences on the level of spending. The extent of the impact on quality and access is critically dependent on the patient's ability to observe the physician's effort, an ability upon which it is difficult to make any empirical statement. The unexpected effect on costs comes in the form of prescriptions (a lump sum method of payment encourages the primary care physician to refer and prescribe more) and long-term effects (if the physician reduces service in the short term, the system can pay for the consequences of this in the long term).

The concrete responses are designed to combine mechanisms so that weaknesses offset each other. Payments with a health outcome (intermediate objectives) serve to increase the capacity of payment by capitation to account for the diverse nature of the physician's work, and to combine public health objectives on the one hand with access and quality objectives on the other. Delegation of responsibility to the medical profession (the regulator sets an envelope which is then managed in a decentralized fashion) can come up against opportunistic behaviours if the decentralization is too weak, and conflicts of interests if it is too strong (physician groups that are too small). After being described as the solution of the future, delegation to physician groups now seems to be marking time, to the benefit of non-financial incentives focussed on patient and doctor information.

What is the evidence on the impact of changes in payment mechanisms or incentives on utilization and costs? Where have the most dramatic changes taken place, and how?

Quantitative data are rare, opportunistic in nature (coming from experiences carried out for other purposes) and always biased. Noteworthy exogenous changes have been made in the United Kingdom, with the introduction of fundholding and PCTs, in Denmark (Copenhagen experiment) and in Germany (envelope and floating points). In the United States, there are numerous reduced-sample experiments (a clinic or a plan) which are difficult to generalize. The reform of Medicare rates has also been a learning ground, but the main problem is that it mixes level and method of remuneration.

Empirical quantitative data suggest that the transition from capitation to FFS increases volumes and reduces prescriptions, although there is no real proof of a reciprocal effect. The quality assessment is more ambiguous, even though patients seem dissatisfied with the lump sum payment method. The target payment experiments seem moderately conclusive in terms of the impact of incentives on the desired outcome. In addition to quantitative evaluations, we have qualitative assessments centered on stakeholders' opinions. Tracking the evolution of physicians' groups in the United States and their internal arrangements is yielding numerous results, which however are difficult to generalize to single-payer contexts.

What non-monetary incentives affect utilization and costs? How do they operate?

Two main innovations are suggested: To assist physicians by providing them with validated and synthesized information about clinical protocols and efficiency; in particular, replacing promotion from the medical products industry; and help physicians and patients get some idea of variations in practices. This second type of incentives is aimed at strengthening patients' control of the physician's effort, which can either increase variability (adapting practices to demand) or decrease it (standardization). This is not simply a matter of finger pointing: physicians may also find it advantageous to compare their practice to that of their colleagues. The impact of these non-monetary incentives is strongly context-dependent, particularly the level of organization of the profession and the ability of physicians to show respect for standards of good practice among their peers.

Figure 1:
Evolution of Prices and Volumes* of Physician Services, 1985-1996

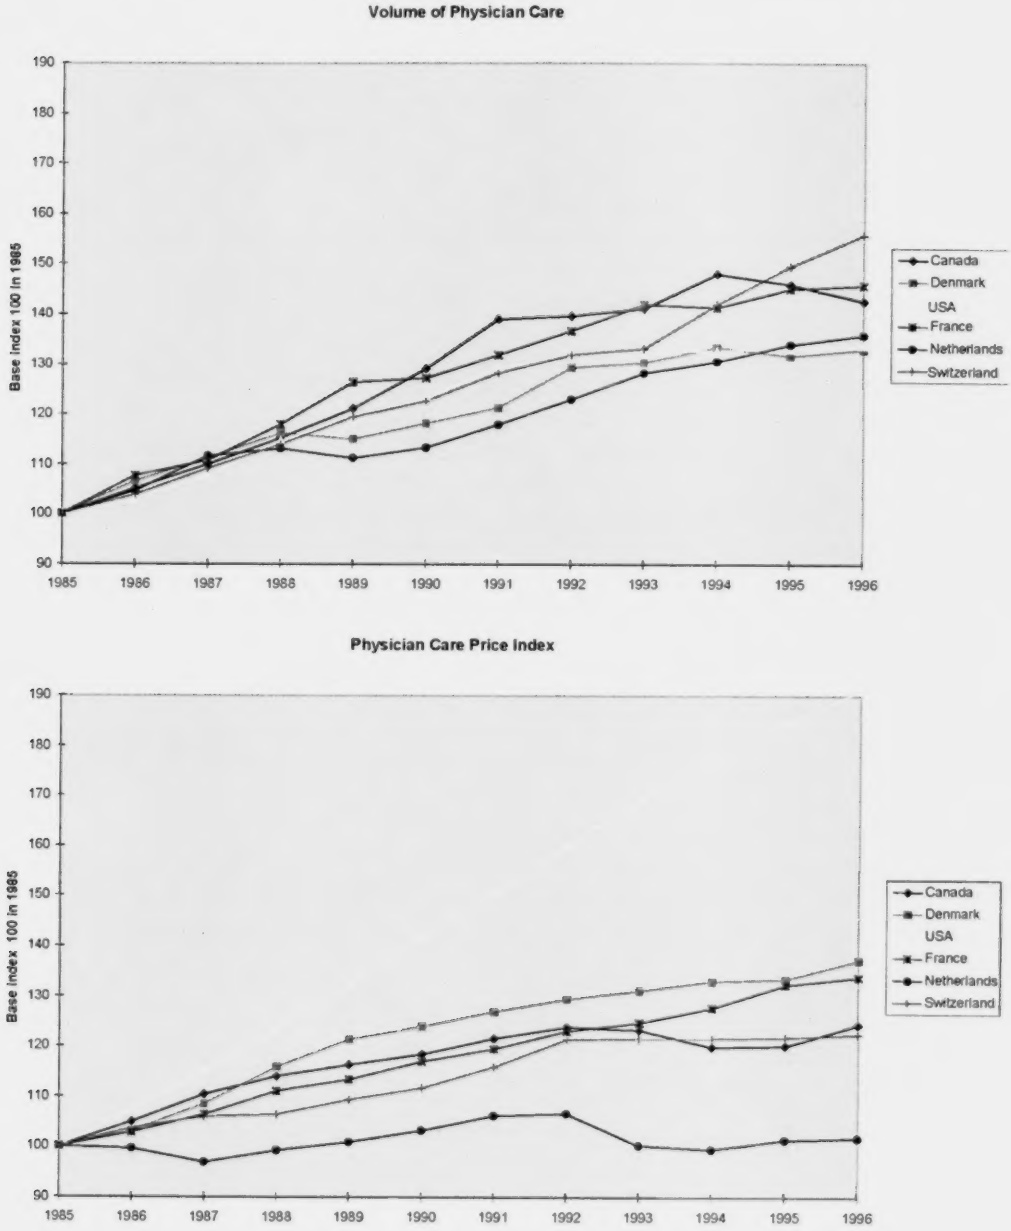

* Volumes correspond to ambulatory care expenditures deflated by the corresponding price index.
Source: *OECD Health Data* 2001.

Notes

1 Increasing quantity can mean changing the structure of services offered by increasing the proportion of better-paid services. Taking the example of Quebec between 1977 and 1983, Rochaix (1993) shows that freezing fees has led to a substantial increase in the proportion of elaborate consultations.

2 A salaried physician could be sanctioned by his employer. With capitation, he will be sanctioned by the patient if inferior quality is noticed and if professionals are in competition to attract clients.

3 Referral is the action whereby one professional refers a patient to another professional.

4 These data allow one to control bias in comparative studies by capturing the effects linked to each individual; however because the data are complicated to obtain, samples are less often representative.

5 Another study on the same set of data appears to show a strong and significant impact of fee-for-service on the volume of urine tests (Kristiansen and Hjortdahl 1992). But Scott and Hall (1995) point out that this effect is measured without correcting for the bias related to the non-independence of the observations (many contacts per patient are observed).

6 This verdict is based on data available at the time this article was written (in 1996 or 1998, depending on the series). Canadian experts might possibly come to another conclusion with more recent data on trends in expenditures, prices and volumes generated.

References

Armour, Brian S., et al. 2001. The effect of explicit financial incentives on physician behaviour. *Archives of Internal Medicine*, 161(10): 1261-2166.

Bocognano, Agnès, et al. *Mise en concurrence des assurances dans le domaine de la santé : théorie et bilan des expériences étrangères*. CREDES-INSEE, 1998.

Brunelle, Yvon, and Howard Bergman. 1999. Capitation, efficience et rationnement. *Ruptures, revue transdisciplinaire en santé*, 6(2): 270-288.

Busse, Rheinardt. Health [sic-TR] Systems in Transition: Germany, European Observatory on Health Care Systems, 2000.

Carlson, Bob. "Capitation: State of the art". 1997. Available httpwww.managedcaremag.com/archives.

Commission on the Future of Health Care in Canada. Shape the Future of Health Care – Interim Report, February 2002.

Coulter, Angela. 1995. Evaluating general practice fundholding in the United-Kingdom. European Journal of Public Health, *5: 233-239.*

Davidson, Stephen, M. Manheim, S. Werner, et al. Prepayment with office-based physicians in publicly funded programs: results from the children's Medicaid program. *Pediatrics*, 89: 761-67.

Debrock, Larry, and Richard, J. Arnould. 1992. Utilization control in HMOs. *Quarterly Review of Economic Finance*, 32: 31-53.

Durieux, Pierre. Actions de diffusion, d'information et de formation médicale continue, in *Comment influer sur les pratiques professionnelles des médecins?* Institut d'Études des Politiques de Santé, 1999.

Emery, J.C. Herbert, Chris Auld, and Mingshan Lu. *Paying for physician services in Canada: the institutional, historical and policy context*, Working paper 99-6. Institute of Health Economics, 1999.

Escarce, José. 1996. Using physician practice cost functions in payment policy: the problem of endogeneity bias, *Inquiry*, 33: 66-78.

Epp, Michael, et al. 2000. The impact of direct and extra billing for medical services: evidence from a natural experiment in British Columbia, *Social Science and Medicine*, 51: 691-702.

Evans, Robert G. 1974. Supplier induced demand : some empirical evidence and implications, in M. Perlman, ed., *The Economics of Health and Medical Care*. McMillan, pp. 162-73.

Evans, Robert G. 1998. New bottles, old wine: right and wrong in physician supply, *Canadian Medical Association Journal*, 158: 757-9.

Ferrall, Christopher, Allan W. Gregory and William G. Tholl. 1998. Endogenous work hours and practice patterns of Canadian physicians, *Canadian Journal of Economics*.

Forsberg, Ewa, Runo Axelsson, and Bengt Arnetz. 2001. Financial incentives in health care. The impact of performance-based reimbursement. *Health Policy*, 58(3): 243-262.

Franck, Clifford R. 1999. Can the pie be divided more fairly? *Contact capitation for specialists*, 5(2). Available http://www.cost-quality.com/5.2art3.html.

Gerdtham, Ulf-G, Jes Sogaard, Fredrik Andersson and Bengt Jönsson. 1992. Econometric analysis of health expenditure: a cross-section study of the OECD countries. *Journal of Health Economics*, 11: 63-84.

Gerdtham, Ulf-G, Bengt Jönsson, M. MacFarlan and H. Oxley. 1998. The determinants of health expenditure in OECD countries, in *Health, the Medical Profession, and Regulation*, under the direction of Peter Zweifel, Kluwer.

Gillett, James, Brian Hutchison, and Stephen Birch. 2001. Capitation and primary care in Canada: financial incentives and the evolution of health service organizations. *International Journal of Health Services*, 31(3): 583-603.

Glied, Sherry. 1998. Payment heterogeneity, physician practice, and access to care. *American Economic Review*, 88(2): 127-31.

Gosden, Toby, Frode Forland, Ivar Sombo Kristiansen, et al. 2001. Impact of payment method on behaviour of primary care physicians: a systematic review. *Journal of Health Services Research and Policy*, 10(1): 44-55.

Grumbach, Kevin, Dennis Osmond, Karen Vranizan, et al. 1998. Primary care physicians' experience of financial incentives in managed care systems. *New England Journal of Medicine*, 339: 1516-21.

Grytten, Jostein and Rune Sorensen. 2001. Type of contract and supplier-induced demand for primary physicians in Norway, *Journal of Health Economics*, 20: 379-393.

Hall, Mark, A., Elizabeth Dugan, Rajesh Balkrishnan, et al. 2002. How disclosing HMO physician incentives affects trust. *Health Affairs*, 21(2): 19-27.

Hanchak, NA. 1997. A performance-based compensation model for obstetricians/gynecologists. *Clinical Obstetrics and Gynecology*, 40: 437-45.

HCFA, Study on Pharmaceutical Benefit Management, PricewaterhouseCoopers LLP.

Health Canada. 2001. *Canada Health Act, 2000-200*, [*sic*-TR] Annual Report.

Hemenway, David. 1995. Financial incentives for childhood immunization, *Journal of Policy Analysis and Management*, 14: 133-139.

Hickson, B., A. Altemeier, and M. Perrin. 1987. Physician reimbursement by salary of fee-for service: effect on physician practice behaviour in a randomized prospective study. *Pediatrics*, 80: 344-50.

Hillman, Alan L., Kimberly Ripley, Neil Goldfard, et al. 1998. Physician financial incentive and feedback: failure to increase cancer screening in Medicaid managed care. *American Journal of Public Health*, 88: 1699-1701.

Hutchinson, James M. and Robert N. Foley. 1999. Method of physician remuneration and rates of antibiotic prescription. *Canadian Medical Association Journal*, 160: 1013-117.

Jelovac, Izabela. 2001. Physicians' payment contracts, treatment decisions and diagnosis accuracy. *Health Economics*, 10: 9-25.

Josseran, L., G. King, and J. Chaperon. 2000. Les Primary Care physicians américains. *Journal d'économie médicale*, 18(6): 375-387.

Kouides, R.W., N.M. Benett, B. Lewis, J.D. Cappuccio, W.H. Barker, and F.M. LaForce. 1998. Performance-based physician reimbursement and influenza immunization rates in the elderly. *American Journal of Preventive Medicine*, 14: 89-95.

Kralewski, John E., et al. 2000. The effects of medical group practice and physician payment methods on costs of care. *Health Services Research*, 35(3): 591-613.

Krasnik, Allan, P. Groenwegen, Poul A. Pedersen. 1990. Changing remuneration system: effects on activity in general practice. *British Medical Journal*, 300: 1698-1701.

Kristiansen, Iwar S., and K. Holthedahl. 1993. The effect of the remuneration system on the general practitionner's choice between surgery consultations and home visits. *Journal of Epidemiology and Community Health*, 47: 481-4.

Kristiansen, Iwar S., and Gail Mooney. 1993. The general practitioner's use of time: is it influenced by the remuneration system? *Social Science and Medicine*, 37: 393-9.

Kristiansen, Iwar S., and Per Hjortdahl. 1992. The general practitioner and laboratory utilization: why does it vary? *Family Practice*, 9: 22-7.

Managed Care Outlook. 2001. "Interest in capitation back off". Available http://www.managedcaremag.com/archives

Mc Guire, Thomas G. 2000. Physician agency in Handbook of Health Economics, *under the direction of Anthony J. Culyer and Joseph P. Newhouse, 1: 463-536.*

Martin, Shelley. 2000. CMA survey shows fee-for-service not dead yet. Canadian Medical Association Journal, *163(5): 601.*

Miller, Robert H. and Harold, S. Luft. 1997. Does managed care lead to better or worse quality of care? *Health Affairs*, 16(5): 7-25.

Mulligan, Pamela. 2002. La capitation: une direction mal avisée dans la réforme des soins de première ligne. Le Médecin de famille canadien, *48: 244-246.*

Namovicz-Peat, S., J. Swann and K. Tureski. HMO & PBM strategies for pharmacy benefits: recent results, current practices, future plans. AIS - Atlantic Information Services, 2001.

Philips, Karen, and William R. Swan. 1996. Health care system in transition: Canada. Preliminary version. World Health Organization - Regional Office for Europe -- Copenhagen.

Red Book 2002. Available http://www.nhs.uk/redbook/2.htm.

Rice, Thomas. 1993a. A model is only as good as its assumptions: a reply to Peele. *Journal of Health Economics*, 12: 209-211.

Rice, Thomas. 1993b. Demand curves, economists, and desert islands: a response to Feldman and Dowd. *Journal of Health Economics*, 12: 201-204.

Robinson, James C. 2001. Theory and practice in the design of physician payment incentives. *The Milbank Quarterly*, 79(2): 148-177.

Robinson, James C. 2001. Physician organization in California: crisis and opportunity. *Health Affairs*, 20(4): 81-96.

Rochaix, Lise. 1993. Financial incentives for physicians: the Quebec experience. *Health Economics*, 2: 163-176.

Rosser, Walter, and Jan Kasperski. 2002. En faveur d'une rémunération mixte. *Le Médecin de famille canadien*, 48: 247-249.

Sandier, Simone. 1990. Le paiement des médecins dans quelques pays de l'OCDE, in *Les systèmes de santé, À la recherche d'efficacité*, Paris: OECD, 1990.

Scott, Anthony, and Jane Hall. 1995. Evaluating the effects of GP remuneration: problems and prospects. *Health Policy*, 31: 183-195.

Scott, Anthony. 2000. Economics of general practice, in *Handbook of Health Economics*, under the direction of Anthony J. Culyer and Joseph P. Newhouse, 1: 1175-1200.

Showstack, Jonathan A., Deborah W. Garnick, Kenneth E. Rosenfeld, et al. 1987. Episode-of-care physician payment: A study of coronary artery bypass graft surgery. *Inquiry*, 24: 376-383.

Stearns, Sally C., Barbara L. Wolfe and David A. Kindig. 1992. Physician responses to fee-for-service and capitation payment, *Inquiry*, 29: 416-429.

Tai-Seale, Ming, Thomas H. Rice, and Sally C. Stearns. 1998. Volume responses to Medicare payment reductions with multiple payers: a test of the McGuire-Pauly model. *Health Economics*, 7: 199-219.

Whynes, David and Darrin L. Baines. 1998. Income-based incentives in UK general practice. *Health Policy*, 43: 15-31.

Wilkin, David, Steve Gillam, and Anna Coleman. The national tracker survey of primary care groups and trusts, 2000/2001.

Commission sur
l'avenir des soins de santé
au Canada

Commission on the
Future of Health Care
in Canada

ÉTUDE Nº 35

L'influence des modes de rémunération des médecins sur l'efficience du système de soins

par

Michel Grignon, Valérie Paris et Dominique Polton

avec la collaboration de Agnès Couffinhal et

Bertrand Pierrard

CREDES, Paris (France)

novembre 2002

N° de Catalogue CP32-79/35-2002F-IN

ISBN 0-662-87884-1

Bien que les opinions exprimées dans ces études n'engagent que les auteurs, chaque étude a été soumise à un processus indépendant d'examen par des pairs. La Commission tient à remercier l'Institut des services et de politiques de la santé (ISPS), des Instituts de recherche en santé du Canada, pour avoir assuré la surveillance et la bonne marche de ce processus d'examen. La participation des auteurs, des examinateurs et de l'ISPS à la réalisation de ces études constitue un apport important aux travaux de la Commission et contribuera à l'héritage qu'elle laissera.

Le générique masculin est utilisé uniquement dans le but d'alléger le texte.

Table des matières

Points saillants iv

Sommaire v

Liste des sigles et signification viii

Question générale 1

Introduction 1

Les différents mécanismes de rémunération des médecins 3

Partie 1 : La littérature économique 5
Les faits et les attendus théoriques simples 5
L'arbitrage coût-qualité-équité : position du problème 6
L'arbitrage coût-qualité-équité : le pouvoir discrétionnaire du médecin 7
L'arbitrage coût-qualité-équité : la capacité du médecin d'augmenter la prescription 13

Partie 2 : À la recherche du mode de rémunération optimal : les enseignements d'une variété d'expériences 14
Combinaisons d'incitations au sein de la rémunération individuelle des médecins 14
Combinaisons d'incitations différentes au niveau individuel et collectif 18
Le groupe de médecins comme lieu d'intégration des objectifs cliniques et économiques 20
Incitations non financières 22

Conclusion : Quels enseignements pour le contexte canadien? 23

Questions spécifiques 24

Notes 27

Bibliographie 28

Points saillants

Cette étude traite de l'impact des modes de rémunération des médecins sur les coûts des soins médicaux.

Il existe trois grands modes de rémunération des professionnels qui dispensent des soins : le paiement à l'acte, la capitation et le salariat. En théorie, le paiement à l'acte peut inciter le professionnel à produire un volume de soins trop important, et les modes forfaitisés peuvent mettre la qualité et l'égalité d'accès en danger. L'importance de ces risques respectifs dépend fondamentalement de la nature et de l'étendue du pouvoir discrétionnaire du médecin sur le patient. Si le médecin influence simplement la demande, les risques sont limités par le contrôle exercé par le patient; si le médecin induit la demande, les risques sont plus importants.

Il n'existe pas de test empirique satisfaisant de la nature du pouvoir discrétionnaire du médecin. Pour autant, les études expérimentales comparant le volume et la qualité des soins selon le mode de rémunération concluent majoritairement à un effet important du paiement à l'acte sur les volumes produits par les médecins de première ligne (généralistes ou pédiatres). Réciproquement, la capitation augmente l'adressage et le volume prescrit, ce qui peut déporter les coûts sur d'autres postes de dépenses de santé. Des expériences naturelles dans le contexte norvégien montrent enfin que l'impact du mode de rémunération est plus faible que celui des caractéristiques sanitaires du patient.

Dans le monde réel (hors des expériences naturelles), les modes de paiement sont rarement purs :

- Première approche : moduler le paiement à l'acte par des incitations financières. Au Royaume-Uni, la délégation de budgets pharmaceutiques aux médecins généralistes a permis de réduire la consommation de médicaments. Ces incitations financières font cependant craindre des conflits d'intérêts entre le revenu du médecin et la qualité qu'il doit fournir. D'autres incitations sont fondées sur des performances sanitaires à atteindre, notamment en matière de dépistage ou de vaccination. Les études sont contradictoires, mais la majorité indiquent un impact positif significatif de ces incitations.
- Deuxième approche : faire dépendre le niveau de la rémunération d'un résultat collectif. Ce type d'approche semble inefficace si la collectivité visée est trop vaste (ensemble des médecins d'un pays), mais le paiement à la capitation de groupes de médecins semble une voie prometteuse pour concilier la maîtrise des coûts et l'organisation efficiente des soins.
- Troisième approche : les incitations non financières (protocoles, évaluation des pratiques). Peu d'études empiriques ont été réalisées sur ce type d'outils incitatifs, mais les premiers résultats indiquent un impact faible, sauf si les « messages » sont communiqués par des leaders d'opinion.

Sommaire

Une littérature économique abondante tente de modéliser la prestation et la consommation des soins comme un marché caractérisé par de nombreuses asymétries d'information, sur lequel le profit est une motivation possible du médecin.

Dans cette littérature, on s'intéresse à ce qui traite de l'impact des modes de rémunération du médecin sur le volume de services qu'il fournit ou prescrit au patient, la qualité de ces services et les inégalités d'accès aux soins.

On distingue trois grands modes de rémunération des médecins : paiement à l'acte, capitation (paiement forfaitaire par patient pris en charge pendant une période de temps donnée), et salariat. Il s'agit bien sûr d'une typologie simplificatrice, la plupart des systèmes nationaux de santé employant une combinaison de ces trois modes de paiement. En outre, le paiement dit à l'acte résulte lui aussi d'une certaine forfaitisation de l'activité médicale.

Les attendus théoriques sont les suivants : en mode de paiement à l'acte, le prix que reçoit le médecin tient compte des coûts fixes de son activité ainsi que des coûts variables, ce qui fait que l'acte marginal supplémentaire accroît toujours le profit monétaire du médecin. Le paiement à l'acte crée donc les conditions favorables à une quantité de services plus importante que ce qu'aurait souhaité le patient; pour peu que le médecin puisse influencer la demande du patient, le paiement à l'acte entraînera une inflation d'actes médicaux. En revanche, en mode capitation, le médecin n'a aucune incitation à produire trop d'actes; on craint au contraire qu'il ne restreigne son effort en réduisant l'accès du patient aux soins, notamment aux ressources immatérielles nécessaires à la production de soins, comme le temps consacré au patient, la capacité et la volonté de l'écouter, et l'effort mental consacré au cas, ce qu'on appelle souvent la qualité des soins. Enfin, toute forfaitisation fait courir un risque de sélection des cas : le médecin percevant la même somme pour des cas nécessitant un effort différent privilégiera les cas les plus simples.

Toujours du côté de la théorie, ces attendus se vérifient plus ou moins selon la nature de l'influence que peut exercer le médecin sur la consommation de soins des patients : une influence forte renforce les effets négatifs attendus (inflation des volumes en paiement à l'acte, qualité inférieure en capitation), une capacité de contrôle de la part du patient les atténue. Deux modèles de l'interaction médecin-patient rendent compte de ce degré d'influence : la concurrence imparfaite et l'induction. En concurrence imparfaite, le patient est à même de juger l'action de son médecin, mais il ne sanctionnera pas les comportements qu'il juge négativement aussi brutalement qu'il le ferait en concurrence parfaite : cette imperfection de concurrence vient de l'attachement du patient à son médecin traitant, qui le connaît personnellement. Dans l'induction, le patient subit plus fortement l'influence du médecin et ne peut contrôler *ex post* le comportement du médecin : ce dernier est en mesure de persuader le patient qu'il reçoit exactement les soins qu'il désire et il n'y a alors plus aucune concurrence.

Le problème est qu'il n'existe aucun test empirique satisfaisant permettant de départager ces deux modèles théoriques. On se tourne alors vers des observations dans le monde réel des interactions patient-médecin sous différents modes de rémunération. Pour inférer de telles observations sur l'impact des modes de rémunération, il faut être certain que l'on compare toutes choses égales par ailleurs. Deux expériences naturelles (affectation au hasard de médecins d'une clinique à des modes de paiement) confirment que le paiement à l'acte augmente les volumes, mais aussi que le niveau de rémunération semble jouer plus que le mode de rémunération. Les résultats des comparaisons « avant-après » (changement brutal et exogène du mode de paiement) montrent que l'impact du mode de rémunération dépend fortement de l'environnement du médecin, notamment de la pression des pairs. Un autre résultat est que le paiement à la capitation augmente la prescription de médicaments.

Dans le monde réel, il est rare qu'un mode de paiement soit pur : la plupart des payeurs cherchent une combinaison optimale, s'appuyant sur l'idée que le degré d'influence du médecin dépend du type de soins fournis. L'innovation majeure a consisté à introduire, au sein de paiements classiques, des correctifs à la marge en fonction de certains résultats sanitaires, le plus souvent mesuré sur une population large (taux de vaccination), ou financiers; on parle ici de paiement à la performance. Ainsi, au Royaume-Uni, la part du revenu indépendante du niveau de services représente 65 %, les paiements à l'acte 25 % et les paiements à la performance 10 %.

Les incitations aux résultats financiers sont efficaces, notamment pour réduire les taux d'hospitalisation, mais ils posent un problème de conflit d'intérêts de nature à abaisser le degré de confiance des patients pour leur médecin et à changer la nature de l'interaction patient-médecin.

Les payeurs préfèrent aujourd'hui les incitations aux résultats sanitaires, plus compatibles avec l'éthique médicale. Au Royaume-Uni, les *target payments* semblent avoir un impact positif sur les taux de vaccination ou de dépistage (observation simple avant-après). Les résultats d'études randomisées sont contradictoires : aucun impact sur le dépistage du cancer d'assurés Medicaid, mais impact positif sur la vaccination d'assurés Medicare ou sur des indicateurs de qualité comme le taux de césarienne, la durée de séjour hospitalier ou le taux de certification, pour des assurés du secteur privé. Rares sont les études qui analysent à la fois l'impact sur les coûts et la qualité.

Une autre innovation consiste à compenser les incitations individuelles par des incitations collectives : en mode paiement à l'acte, la valeur unitaire diminue quand le volume collectif augmente. Appliqué à un collectif trop large, ce système engendre un effet de passager clandestin, chaque individu augmentant ses volumes pour compenser la baisse de prix. Des contrôles individuels d'activité, ou des tarifs dégressifs sont alors nécessaires. Une autre solution consiste à réduire la taille du collectif bénéficiaire des incitations, sur le modèle des *primary care groups* britanniques, ou des *medical groups* aux États-Unis; la difficulté est alors de trouver l'équilibre entre la responsabilisation des médecins pour le collectif, et la solidité financière et technique du groupe, qui suppose une taille minimale.

Enfin, la plupart de ces incitations collectives reposent sur des éléments non financiers, comme la diffusion de protocoles de bonnes pratiques, ou l'évaluation de la pratique individuelle par les pairs, voire le conventionnement sélectif sur la base de pratiques définies en commun. L'impact de ces incitations non financières n'a cependant pas encore été évalué.

Liste des sigles et signification

HMO : *Health Maintenance Organization*

Régime de soins de santé à panel de médecins restreint (le patient n'est pas pris en charge s'il consulte hors panel)

MEDICAID : Assurance-maladie publique pour les pauvres aux États-Unis

MEDICARE : Assurance-maladie publique pour les plus de 65 ans et les personnes invalides aux États-Unis

PCG/T : *Primary Care Group* ou *Trust*

Groupe de médecins généralistes au Royaume-Uni, délégataire d'un budget global et prenant en charge tous les soins d'une population

PPA : Parité de pouvoir d'achat

Unité permettant de comparer des dépenses d'un pays à l'autre en s'affranchissant de la variabilité des taux de change

PPO : *Preferred Provider Organization*

Régime de soins de santé à panel de médecins recommandés (le patient n'est pris que partiellement en charge s'il consulte hors panel)

Question générale

Comment les mécanismes de rémunération et les incitations influent-ils sur l'utilisation et les coûts des services liés aux soins de santé? Dans quelle mesure des changements au niveau des politiques, des pratiques et des incitations changeraient-ils les structures de coût et le cheminement des soins de santé?

Introduction

L'efficience du système de santé intéresse l'économie publique et la politique économique parce que la dépense de santé est toujours au moins mutualisée, voire socialisée. La question de l'efficience a longtemps été limitée à la maîtrise de l'évolution des coûts des soins de santé, mais elle se pose maintenant de façon plus complexe : comment concilier une dépense raisonnable avec une exigence de qualité et d'équité?

Cette question a motivé une abondante littérature économique, modélisant les caractéristiques du marché des soins médicaux et les comportements des producteurs et des consommateurs de soins, afin de proposer des contrats optimaux au régulateur pour satisfaire ces trois objectifs contradictoires (maîtrise de la dépense, qualité, équité). Cette littérature théorique, centrée sur les comportements cachés au sein du trio payeur-patient-médecin, a débouché sur des questions empiriques non résolues, notamment au sujet de l'étendue de l'influence du médecin sur le patient.

Nous nous intéressons ici au volet de cette littérature qui traite de l'impact du mode de rémunération du médecin sur le volume de services qu'il fournit ou prescrit au patient, la qualité de ces services, et les inégalités d'accès aux soins. La façon de payer le médecin est un vrai choix stratégique et il n'existe pas de mode de paiement « naturel ». En effet, parce qu'il est soumis à une obligation de moyens et non de résultats (pour des raisons d'incertitude), le médecin n'est pas véritablement un producteur classique, qui vend un résultat et prend le risque que celui-ci ait une valeur inférieure à son coût de production. On parle du reste de rémunération des médecins, ce qui en fait des facteurs de production, plutôt que de prix de vente des services médicaux. Pour autant, le médecin n'est pas non plus un simple facteur de production, parce que son degré d'autonomie dans l'agencement des actions élémentaires qui concourent à la production de son service est une composante de la qualité des services qu'il offre.

Après une brève présentation des différents modes de rémunération des médecins, nous synthétisons, dans la partie 1, la littérature économique consacrée à leur impact sur le coût des soins de santé. Nous explicitons les enjeux théoriques des différents mécanismes de paiement et examinons dans quelle mesure les études empiriques menées dans différents contextes nationaux valident ces attendus théoriques.

Les économistes font l'hypothèse que, même si le profit du médecin n'est pas l'unique moteur de la décision médicale, il en est un élément. Cette hypothèse est partagée et confortée par la sociologie médicale, qui montre que, lorsque les conséquences d'une décision médicale sur

le bien-être du patient sont incertaines, les arbitrages du médecin en termes de loisir, de réputation ou de revenu prennent une place plus importante. Il n'est alors plus sûr que le patient reçoive exactement la quantité de soins nécessaire à son traitement.

Implicitement, les questions d'analyse économique sont donc du type suivant : étant données les motivations des médecins, quel impact a le mode de paiement sur la dépense médicale? Cette attitude ne signifie pas que les motivations autres que le profit (les normes professionnelles, le respect des pairs ou l'intérêt du patient) sont sans importance, mais plutôt qu'on peut faire l'hypothèse que les modes de rémunération sont sans impact sur elles. Dans la réalité, cette hypothèse est certainement fausse et les expériences de modification des modes de rémunération des médecins permettent alors de comprendre pourquoi les mécanismes mis en place peuvent s'écarter fortement des recommandations économiques, notamment parce que le mode de rémunération peut interférer avec ces autres motivations du médecin (partie 2).

Les différents mécanismes de rémunération des médecins

Il est d'usage de distinguer trois grands modes de rémunération des médecins :

- La rémunération à l'acte
- La capitation, qui est un paiement forfaitaire par patient pris en charge pendant une période de temps donnée
- Le salariat

Selon les pays, l'une ou l'autre de ces trois formes de rémunération est utilisée pour les généralistes. Les spécialistes sont en général payés à l'acte ou salariés.

Cette typologie classique suscite quelques réflexions.

Tout d'abord, la rémunération globale d'un médecin peut combiner plusieurs méthodes de paiements : les paiements mixtes sont pratiqués dans certains systèmes de santé, comme on le verra dans la partie 2.

Ensuite, même s'il est commode d'opposer ces trois mécanismes, on peut aussi les considérer comme s'échelonnant sur une échelle de forfaitisation croissante, qui permet aussi d'imaginer des situations intermédiaires :

- À une extrémité, le paiement à l'acte correspond au paiement le plus décomposé, le moins forfaitaire, de l'activité médicale. Malgré tout, il s'agit encore d'un forfait : lorsqu'une consultation est payée à un tarif unique, comme en France par exemple, il importe peu que cette consultation soit courte ou longue, qu'un examen clinique soit réalisé ou que le médecin renouvelle simplement une ordonnance. On peut d'ailleurs noter que les degrés de forfaitisation des nomenclatures utilisées dans les différents pays pour tarifer les actes varient et qu'une analyse comparative de ces nomenclatures pourrait permettre de qualifier différents types de paiements à l'acte.
- La capitation représente un degré de forfaitisation supplémentaire, puisque le médecin est payé de la même manière pour un patient quelle que soit la quantité de services qu'il lui fournit. Le revenu du médecin ne varie qu'en fonction du nombre de malades pris en charge.
- Le salariat représente la situation extrême du paiement forfaitaire dans laquelle le revenu est invariant quelle que soit l'activité du médecin, qu'il s'agisse du nombre de patients soignés ou de la quantité de services fournis par patient.

Sur cette échelle, on peut imaginer des situations intermédiaires, par exemple entre le paiement à l'acte et la capitation globale : un paiement forfaitaire par épisode de soins ou un paiement forfaitaire pour le suivi d'une pathologie chronique pendant une période de temps. Quelques expérimentations avec de tels mécanismes seront évoquées dans la partie 2.

En résumé donc, même si l'on oppose classiquement – et c'est ce que nous ferons dans la revue de la littérature économique ci-dessous – trois modes de rémunération « archétypaux », il n'est pas interdit de concevoir des modalités intermédiaires.

Enfin, dans les formes de paiement des professionnels de la santé, on voit apparaître des mécanismes qui ne correspondent à aucun des trois modèles évoqués ci-dessus, mais qui s'apparentent à des mécanismes d'intéressement aux résultats, certains financiers (contrôle des coûts) et d'autres visant la qualité du service médical.

Ce type de mécanismes, dont des illustrations seront données dans la partie 2, pourrait être considéré comme un quatrième mode de rémunération, alternatif aux trois précédents. C'est d'ailleurs ce que font certains auteurs qui distinguent désormais les quatre modes, donnant souvent au quatrième l'appellation de « paiement à la performance ». Dans la pratique, cependant, ce type d'intéressement n'intervient que comme un complément à la marge du mode principal de rémunération et peut difficilement être considéré comme une alternative; il s'agit plutôt d'un appoint aux trois grands modes de paiement. Dans l'avenir, il est possible qu'il prenne une part croissante dans la rémunération.

Partie 1 :
La littérature économique

Voici un bref aperçu de la littérature économique traitant de l'impact du mode de paiement des services des médecins sur le coût budgétaire total de la santé.

Les faits et les attendus théoriques simples

Sur la base des données agrégées, la dépense totale de santé d'un pays est affectée par les variables d'offre en général et par le mode de rémunération des médecins en particulier. Sur dix-neuf pays de l'OCDE, Gerdtham et coll. (1992) constatent que, toutes choses égales par ailleurs, le « paiement à l'acte des médecins » (c'est-à-dire une variable indiquant que ce mode de paiement est majoritaire dans le pays) augmenterait de 11% la dépense de santé. Une étude plus récente, utilisant des données de panels (22 pays de l'OCDE entre 1970 et 1991), ne trouve plus d'effet propre au paiement à l'acte, mais un effet indirect : la densité médicale augmente la dépense quand les médecins sont rémunérés à l'acte (Gerdtham et coll. 1998). Ces liens au niveau des données agrégées sont cependant difficiles à interpréter car il est possible que la dépense nationale totale et des arrangements institutionnels particuliers, comme le paiement à l'acte, soient tous deux corrélés positivement à une troisième variable, par exemple le fait que les médecins exercent de manière isolée.

La littérature économique tente donc de décrire le cheminement micro-économique par lequel le mode de rémunération du médecin pourrait avoir une influence sur la dépense médicale; pour formaliser ce cheminement, on caractérise un mode de paiement par le degré auquel le paiement est forfaitisé. Dans la suite de cette première partie, nous nous concentrons sur l'opposition entre le système de paiement forfaitaire (capitation et salariat) et celui du paiement à l'acte.

Nous pouvons relever tout d'abord les attendus de l'impact des modes de paiement sur le coût des soins de santé en faisant abstraction des autres objectifs du système de santé (la qualité et l'équité). Pour ce faire, décrivons rapidement l'activité du médecin : pour soigner les patients, il utilise des ressources. Certaines ressources comme le cabinet doivent être présentes qu'il y ait ou non des patients; d'autres ne sont mobilisées qu'en présence d'un client. Dans la réalité actuelle, le médecin ne fixe pas lui-même son prix, il le reçoit d'un payeur. Les ressources utilisées dans la production sont de deux types, ressources matérielles quantifiables et ressources immatérielles difficilement quantifiables. Les premières sont, par exemple, les biens consommables de l'activité médicale, les secondes réunissent le temps que le médecin consacre à chaque patient, sa compétence (qui est fonction de sa formation continue, du soin qu'il prend à se tenir informé), sa capacité à écouter le patient, et son effort mental. L'économie désigne habituellement le niveau de ressources immatérielles par « l'effort du médecin ». Une différence importante entre ressources matérielles et immatérielles est que le payeur peut tenir compte des premières dans son paiement, mais plus difficilement des secondes. En effet, il est difficile pour un payeur de rémunérer une ressource quand il ne peut avoir la preuve qu'elle a bien été utilisée.

Muni de ce modèle simplificateur, que peut-on dire du mode de paiement?

En mode de paiement à l'acte, le prix tient compte des coûts fixes et des coûts variables (sinon, le médecin refuse de travailler) et est donc supérieur au coût moyen des seules ressources variables : soigner un patient supplémentaire apporte donc un profit financier au médecin. Si, de surcroît, le médecin dispose d'un pouvoir quelconque sur la demande du patient, le paiement à l'acte crée les conditions favorables à une quantité (et donc à une dépense) de services plus importante que ce qu'aurait souhaité le patient, ou que ce qui aurait été médicalement nécessaire dans son cas. Dans ce modèle, et toujours si le médecin exerce un pouvoir sur le patient, si le payeur diminue le prix unitaire, le médecin réagira en augmentant la quantité[1] pour maintenir son profit; on explique ainsi qu'une baisse du prix des soins entraîne une augmentation de l'offre de services.

En revanche, en mode capitation, le médecin n'est pas remboursé proportionnellement aux ressources qu'il engage et n'a donc aucun intérêt à la multiplication des actes, puisqu'il perd alors de l'argent ou gaspille son effort. Il préfère traiter le patient en utilisant le moins possible de ressources pour atteindre une qualité donnée.

L'arbitrage coût-qualité-équité : position du problème

Si la question se résumait à la maîtrise des coûts, on pourrait se demander pourquoi tous les régulateurs n'ont pas opté pour une forme ou une autre de paiement forfaitaire. Il existe bien évidemment des raisons historiques qui maintiennent le paiement à l'acte en dépit de la supériorité évidente du forfait comme instrument de maîtrise budgétaire (voir, par exemple, Emery, Auld et Lu 1999). Cependant, sur le territoire culturellement homogène des États-Unis, on constate des arrangements différents selon les payeurs : certains préfèrent des formes de capitation, d'autres le paiement à l'acte, ces derniers survivant et semblant même regagner des parts de marché au cours de la période récente.

Il existe donc certainement des raisons liées à l'efficacité économique pour expliquer que le paiement forfaitaire n'ait pas été adopté universellement :

- Une première raison est liée à la qualité du service médical obtenu : si la forfaitisation permet de résoudre, par construction, le problème de l'augmentation des volumes de soins dispensés par le médecin, elle fait peser le risque que le médecin fournisse trop peu de services (consultations, examens) et trop peu de ressources immatérielles (consultations plus courtes, moins d'attention) au patient. Le régulateur peut bien évidemment imposer un minimum de services par patient, mais il aura du mal à contrôler le niveau des ressources immatérielles. Si le médecin est payé pour la prise en charge d'un patient et n'est sanctionné d'aucune manière[2], il a tout intérêt à percevoir le forfait et à ne pas fournir les services et l'effort correspondants. La littérature économique tente d'éclaircir ce point et de définir les circonstances dans lesquelles un forfait met la qualité médicale en danger. Plus généralement, le forfait peut être vu comme une délégation au médecin de

la responsabilité d'agencer au mieux les services qui concourent à la santé, alors que le paiement à l'acte partage ce rôle entre médecin et régulateur. En présence de payeurs multiples, le paiement à l'acte pose un problème supplémentaire de non-cohérence des systèmes de prix, mais ce problème n'a été étudié à notre connaissance que pour l'offre hospitalière (Tai-Seale, Rice et Stearns 1998).

- Ce problème de qualité peut aussi avoir des conséquences sur la dépense : le médecin n'est pas seulement un producteur de services, il est aussi prescripteur. En règle générale, la capitation s'accompagne d'une responsabilité d'aiguillage du médecin de première ligne : il prend les décisions concernant les volumes d'analyses, de médicaments, de consultations spécialisées ou de soins hospitaliers. Si le médecin réduit l'intensité de son effort à cause du forfait, tout en restant soucieux de la santé de son patient, il peut fort bien générer un fort volume de coût de soins de santé en augmentant sa prescription.
- Enfin, se pose le problème de l'universalité de l'accès aux soins : le forfait entraîne toujours un risque financier pour le médecin; si les médecins ont de l'aversion pour les situations incertaines, ils vont refuser de prendre en charge les patients à forte variance de coût *ex ante*. Si les médecins savent mieux sélectionner que les payeurs, ils vont gagner de l'argent en traitant les personnes dont le forfait est élevé et en refusant les soins aux autres (voir, par exemple, Mulligan 2002).

Au total, la question devient donc : quelle forme de paiement permet le mieux de concilier les objectifs de maîtrise des dépenses, de qualité du service médical et d'universalité d'accès aux soins? Nous nous intéressons d'abord aux modèles théoriques qui expliquent le pouvoir discrétionnaire du médecin sur la consommation du malade et qui s'opposent sur l'existence d'une capacité du médecin à « induire » la demande de son patient (Evans 1974). Cette capacité à induire a des conséquences importantes pour notre propos, car elle augmente le risque que les paiements forfaitaires conduisent à une diminution du service médical reçu par le patient. Nous complétons notre présentation par une analyse du comportement du médecin comme prescripteur de services médicaux qu'il ne fournit pas lui-même.

L'arbitrage coût-qualité-équité : le pouvoir discrétionnaire du médecin

Approche théorique

Nous avons vu précédemment que le médecin tirait profit du paiement à l'acte s'il avait la possibilité d'imposer au patient plus de services que celui-ci n'en souhaite ou n'en a besoin. D'où vient une telle possibilité?

Un accord assez large semble se faire sur l'idée que le médecin dispose effectivement, dans l'interaction avec ses patients, d'une supériorité qui lui permet d'influencer la consommation de ses services.

Une raison pour laquelle le médecin dispose d'une supériorité est qu'il en sait plus que son patient. Une abondante littérature théorique traite du fait que la supériorité des connaissances suffit à un expert pour imposer une relation d'agence, c'est-à-dire une relation dans laquelle le profane s'en remet totalement à l'expert. Cette littérature conclut qu'en situation de concurrence des experts, et si le profane peut se faire une idée assez précise du lien existant entre l'effort de l'expert et son résultat, alors la supériorité des connaissances ne suffit pas à créer l'agence. L'expert vend un bien dit « d'expérience », sur lequel l'acheteur peut finir par se faire une idée. En revanche, si une incertitude radicale interdit à l'acheteur de se faire une idée quelconque sur l'impact de l'effort de l'expert sur le résultat qu'il obtient, alors la relation d'agence peut exister. On dit que l'expert vend un bien de « confiance » car l'acheteur profane doit lui faire une entièrement confiance.

Qu'en est-il pour les biens médicaux? Rice (1993) avance l'idée radicale qu'il n'existe simplement pas de demande de soins éclairée et autonome de la part du patient. Il appuie sa démonstration sur le fait que, dans l'expérience de la Rand, les soins supplémentaires que s'offrent les patients les mieux couverts ne sont pas, au dire d'experts indépendants, des soins vraiment appropriés compte tenu de leur état de santé.

L'idée qu'il n'existe aucune demande autonome du patient en matière de soins est sans doute excessive (nous faisons tous des choix sanitaires indépendants de nos médecins) mais, en revanche, il est certain que le service médical rendu par le médecin est pour une part non observable. Cette difficulté à juger le service médical rendu constitue sans doute l'une des raisons pour lesquelles les médecins n'ont pas le droit, sauf exception, dans les pays développés, de détenir des pharmacies ou d'exercer le métier de vendeur de médicaments : s'ils pouvaient augmenter leur profit de cette manière, ils pourraient abuser de leur position d'expert pour convaincre les patients de leur intérêt à consommer des médicaments.

On peut aussi faire quelques prédictions *a priori*. Par exemple, il est certainement plus difficile d'observer la qualité du service d'un spécialiste que l'on voit rarement : pour résoudre l'asymétrie d'information, le régulateur préférera faire observer la qualité du service de ce spécialiste par un autre médecin, en soumettant le recours à un adressage[3] par un médecin traitant de première ligne. En revanche, les preuves empiriques d'un degré d'induction de la part de médecins sont très difficiles à réunir : même si l'on mesure une différence de traitement pour deux malades identiques auprès de deux médecins différents, et si l'on arrive à relier cette variation de pratique à l'intérêt économique du médecin, encore faudra-t-il être certain que la variation n'est pas ressentie par le patient comme une dégradation du service qu'il reçoit.

En effet, la relation d'agence suppose non seulement que le médecin impose ses vues au patient, mais aussi que le patient ne s'en aperçoive pas (il fait confiance à l'expert). Or, comme le montre McGuire (2000), on peut très bien imaginer que le médecin parvienne à imposer ses vues même si le patient s'aperçoit que le médecin ne fait pas exactement ce que le patient aurait désiré, ou ce que le médecin ferait pour lui-même. En termes techniques, la relation d'agence n'est pas nécessaire pour qu'existe un pouvoir discrétionnaire du médecin sur le patient : il suffit que le médecin soit en situation de concurrence imparfaite face aux patients pour que ceux-ci acceptent de sa part une prestation de services non totalement satisfaisante.

Une bonne raison pour qu'il y ait situation de concurrence imparfaite des médecins face aux patients est l'attachement du patient à certaines caractéristiques intrinsèques de son médecin qui fait qu'il n'accepterait pas volontiers d'en chercher un autre. Cet attachement du patient à « son » médecin (médecin de famille, source habituelle de soins) est abondamment documenté et s'explique par le fait qu'une fréquentation de longue durée permet un suivi spécialisé du cas du patient. Cet attachement du patient au médecin concerne évidemment plus le médecin généraliste (ou de première ligne) ou encore le spécialiste pour une maladie chronique.

Cet attachement du patient à un médecin particulier fait que les médecins ne sont pas des substituts parfaits : chaque médecin dispose d'une latitude face à son patient, et peut lui imposer des choix différents de ceux que ferait le patient spontanément s'il pouvait sans dommage remplacer son médecin par un autre. Disposer d'une latitude se traduit en termes économiques par « disposer d'un pouvoir de marché » et signifie se comporter comme un monopole. Précisément, le médecin est en situation de concurrence monopoliste face à son patient : comme un monopole, le médecin peut tirer le meilleur parti de la disposition à payer de son patient en jouant sur les prix et les quantités offertes (alors qu'en concurrence parfaite, il y a un seul prix, celui du marché); pour autant, si le médecin « en fait trop » (s'éloigne trop des attentes ou des besoins de son patient), celui-ci le quitte pour un autre médecin.

On peut même souligner que l'attachement et l'agence opèrent de manière complémentaire : quand le patient voit rarement le médecin, il a peu d'attachement à la personne du médecin, mais il a aussi plus de chance d'être en relation d'agence et de devoir lui faire confiance aveuglément; en revanche, quand le patient est engagé dans une relation de long terme avec son médecin, il observe plus facilement la qualité du service, mais il a plus de difficulté à faire jouer la concurrence et à s'opposer à des prestations de services qui le laissent insatisfait.

Quelle conséquence peut avoir la nature de ce pouvoir discrétionnaire du médecin sur le problème qui nous occupe? Schématiquement, plus on s'approche d'une situation de concurrence monopoliste et plus le médecin doit tenir compte de la menace que fait peser sur lui le départ du patient : en mode paiement à l'acte, cette menace limite le pouvoir du médecin de dispenser trop d'actes dont le patient ne veut pas; en mode capitation, elle limite le pouvoir du médecin de trop réduire le volume de services et, surtout, l'effort qu'il consacre à son patient. Si l'attachement des patients pour un médecin donné est une variable continue, le médecin opère un arbitrage entre la taille de sa liste et le bénéfice qu'il retire de chaque inscrit. On dit alors que le médecin influence la consommation du patient.

En revanche, plus on s'approche de la relation d'agence, et moins le patient est apte à faire peser une menace sur le médecin, qui peut fournir trop de services s'il est rémunéré à l'acte, ou pas assez d'effort en mode de paiement forfaitaire. En ce cas, on parle d'induction de la demande par le médecin.

Une abondante littérature tente de prouver empiriquement et de manière indirecte que le médecin dispose d'un pouvoir discrétionnaire absolu, car non contrôlé par le patient. Un test classique consiste à mesurer la réponse des médecins à une variation de la densité médicale en contexte de paiement à l'acte. Rappelons que, en cas d'induction, le médecin est hors

concurrence : si la densité médicale augmente, le médecin aura un moins grand nombre de patients en moyenne (dans le cas de l'induction, la qualité du médecin joue peu sur son attractivité puisqu'il n'est pas en concurrence) et réagira donc pour préserver son revenu en augmentant le volume des services utilisés par ses patients. En revanche, en concurrence monopoliste, l'augmentation de la densité médicale renforce le risque pour le médecin que son patient le quitte (le coût d'une rupture est moindre pour le patient) et il ne va donc pas imposer un écart encore plus important entre la consommation souhaitée par le patient et les services fournis.

Outre les questions empiriques (caractère vraiment exogène de l'augmentation de densité, difficulté à observer des variations importantes), ce test n'est pas parfait. Il repose sur l'hypothèse contestable qu'en concurrence monopoliste, l'augmentation de la densité médicale facilite le départ du patient mécontent; en fait, si l'attachement du patient dépend de caractéristiques personnelles du médecin qui ne sont pas affectées par la densité médicale, on peut observer une augmentation du nombre d'actes par suite d'une augmentation de la densité médicale dans un contexte d'influence. Pauly et Satterthwaite (1981) font une objection du même type : une densité supérieure de médecins augmente la capacité de chaque médecin d'influencer la demande par un mécanisme de médicalisation des attentes de la population.

Au total, il semble qu'on ne puisse trancher sur le degré d'induction à partir de mesures du niveau d'activité par médecin. Les enquêtes directes auprès des patients sur le degré de satisfaction et sur les raisons pour lesquelles ils choisissent ou quittent tel ou tel médecin seraient sans doute d'un grand intérêt sur ce point. Mais force est de constater qu'il n'y a pas eu de mesure du degré d'induction fondée sur des déclarations directes de patients. Une indication précieuse ressort du fait qu'aux États-Unis, les assurés du programme Medicare les plus malades préfèrent rester dans les régimes de paiement à l'acte et garder la liberté d'accès au médecin de leur choix plutôt que de bénéficier de la couverture plus étendue proposée par les HMO. On peut donc craindre que la latitude du médecin à convaincre le patient que ce dont il a besoin est justement ce qui maximise le revenu du médecin n'augmente avec le degré de morbidité du patient.

Approches empiriques

Face à un constat de variation de la pratique médicale, il est impossible de savoir *a priori* si une pratique est excessive ou si c'est l'autre qui est restrictive. On peut comparer *a posteriori* les pratiques à une norme technique, comme une recommandation, ou à une norme statistique comme la pratique moyenne, mais rien ne valide de telles comparaisons.

On ne peut donc que mesurer l'impact du mode de rémunération du médecin sur le volume de services consommé par patient, la qualité et l'universalité, sans se prononcer à partir de telles études sur le bon type de paiement. Pour mesurer cet impact, nous cherchons des comparaisons toutes choses égales par ailleurs, sauf le mode de paiement. Scott et Hall (1995) ont recensé sept études empiriques publiées en anglais sur ce thème et soulignent que ce nombre limité est lié au fait qu'il s'agit d'études « opportunistes », utilisant des données recueillies à d'autres fins. Gosden et coll. (2001) recensent une huitième étude.

Pour que la comparaison ait un sens, il faut d'abord être certain que l'on se trouve dans des contextes comparables : comparer l'impact de systèmes de paiements différents dans des zones géographiquement ou socialement très éloignées n'aurait pas grand sens. Il faut donc trouver des contextes homogènes avec une variabilité suffisante des modes de paiement. Un deuxième problème lié à ce type de comparaison est qu'il est difficile de s'assurer que toutes choses autres que le mode de paiement soient bien égales par ailleurs : le fait qu'un patient opte pour un médecin rémunéré à l'acte ou en capitation peut être corrélé avec des caractéristiques non observables, mais elles-mêmes liées à l'utilisation du système de soins. De même, les médecins peuvent se spécialiser par types de contrats (Glied 1998), là encore pour des raisons non indépendantes de leur mode de travail et du volume de services qu'ils dispensent. Enfin, il est difficile de s'assurer que le niveau du paiement est bien le même d'un mode de paiement à l'autre et qu'on ne mesure pas l'effet combiné d'une différence de mode et de niveau de paiement.

Hickson et coll. (1987) ont mené une étude expérimentale en contrôlant les deux premiers problèmes : quinze pédiatres, membres d'une même clinique, sont alloués aléatoirement à un mode de paiement (salariat ou paiement à l'acte). L'étude compare alors le nombre de visites préventives des salariés et des médecins payés à l'acte : à caractéristiques observables des médecins et des patients contrôlées, les pédiatres payés à l'acte montrent significativement plus de séances.

En outre, ce surcroît de volume reflète une variation ambiguë de la qualité : les patients traités par les médecins payés à l'acte affirment bénéficier d'un meilleur suivi; en revanche, le volume des séances préventives qu'on leur propose s'éloigne plus des recommandations de l'Académie américaine des pédiatres que celui des médecins salariés. Gosden et coll. (2001) soulignent que cette différence moyenne entre médecins salariés et rémunérés à l'acte recouvre deux phénomènes distincts : les médecins salariés sont moins souvent en recommandation « excessive » de séances que ceux rémunérés à l'acte, mais les patients des médecins salariés observent aussi moins les recommandations de leur médecin.

Une autre étude expérimentale avec affectation aléatoire des médecins entre les modes de paiement est celle de Davidson et coll. (1992) qui porte sur 80 médecins traitant des enfants bénéficiaires du programme Medicaid aux États-Unis. L'étude suit trois groupes, le groupe de référence, payé à l'acte, un groupe payé à l'acte mais touchant un prix plus élevé, et un groupe payé à la capitation. Le volume de séances de soins primaires augmente pour les deux groupes « expérimentaux », ce qui souligne l'impact du niveau de rémunération, indépendamment du mode de paiement. Cependant, le volume augmente plus dans le groupe des médecins rémunérés à l'acte (+0.8-0.9) que dans le groupe des médecins rémunérés à la capitation (+0.5-0.6).

Le prix à payer pour ces gains méthodologiques (affectation aléatoire des médecins entre les modes de paiement) est évidemment la faiblesse de l'échantillon et le caractère peu généralisable des résultats.

Nous nous tournons donc vers des comparaisons « avant-après » dans lesquelles un même groupe de médecins et de patients s'est vu imposer par le payeur un changement de mode de paiement. En effet, nous pouvons faire l'hypothèse que, dans ce cas, le mode de paiement change vraiment de manière exogène et observer l'effet pur de tout biais. En outre, les réformes se font souvent autant que possible « à revenu constant » pour les médecins et nous pouvons donc mesurer l'effet du mode de paiement indépendamment de l'effet du niveau de revenu.

Une première observation de ce type a été faite par Stearns et coll. (1992) et révèle la faible efficacité de la capitation sur le volume de services fournis : dans un régime de soins de santé pour les fonctionnaires du Wisconsin, les médecins de première ligne sont passés du paiement à l'acte à la capitation individuelle. Simultanément, le tarif unitaire de l'acte de spécialiste est fortement réduit. Il y a eu paradoxalement augmentation du nombre de séances ambulatoires, mais c'est le nombre de séances chez les spécialistes qui a augmenté; il y a lieu de penser que les spécialistes ont accru leur auto-adressage pour compenser la baisse de tarif. Le nombre de séances chez les généralistes est resté inchangé et le passage à la capitation n'a donc pas eu d'effet. Il est toutefois possible qu'un autre élément ait perturbé l'expérience : simultanément, les généralistes ont aussi bénéficié d'un intéressement à limiter les dépenses hospitalières. Il est donc possible qu'ils aient été motivés par cet intéressement et aient mis davantage l'accent sur la médecine de première ligne pour éviter des hospitalisations. De fait, l'étude montre une baisse sensible du taux d'hospitalisation (mais non de la durée de séjour). Cette étude n'est pas totalement exempte de biais, car certains médecins de première ligne ont quitté le régime ou ont refusé des patients du régime (ou d'offrir certains services). Des patients ont pu aussi quitter le régime car, outre le changement de mode de rémunération, il y a eu passage en HMO exclusif (non prise en charge de l'assuré s'il consulte hors du panel), alors que le régime fonctionnait auparavant en PPO (moindre prise en charge de l'assuré s'il consulte hors du panel).

Une expérience contrôlant mieux ces départs volontaires a été menée au Danemark (Krasnik 1990). Les généralistes de la ville de Copenhague sont passés de la capitation pure à une formule combinée de capitation et de paiement à l'acte, tandis que les médecins de la région restaient en mode capitation. L'auteur peut donc comparer l'évolution des volumes dans le groupe « soumis à l'expérience » (les généralistes de Copenhague) et dans le groupe « témoin ». Le volume de services offert par les médecins du groupe « expérimental » a fortement augmenté à la suite du passage au paiement à l'acte.

Cependant, cet effet n'est pas universel et l'expérience norvégienne semble moins concluante quant à l'impact du paiement à l'acte. En utilisant des chroniques de contacts par patient et par médecin[4] en Norvège, Kristiansen et Holtedahl (1993) montrent que le paiement à l'acte hausse le nombre de visites à domicile toutes choses égales par ailleurs (l'état de santé du patient étant cependant inconnu), mais que l'effet du mode de paiement reste faible par rapport à l'influence des caractéristiques individuelles du patient : le médecin reste plus motivé par le besoin sanitaire du patient que par son revenu[5]. Cette primauté du clinique sur l'économique en Norvège semble confirmée par Grytten et Sorensen (2001), qui montrent que les médecins rémunérés à l'acte ne font pas plus d'examens que les médecins salariés, même après avoir contrôlé les éléments qui incitent les médecins à choisir tel ou tel type de contrat. Selon ces auteurs, la primauté du facteur

clinique serait due principalement à l'existence d'un fort contrôle par les pairs en Norvège, qui empêcherait le médecin de tirer parti de sa supériorité sur le patient.

Outre un effet dommageable sur la qualité moyenne, l'induction peut aussi avoir une conséquence dommageable sur l'équité du système : les populations vulnérables (enfants, personnes âgées, malades mentaux, pauvres, minorités linguistiques) ont plus de mal que les autres à contrôler et à observer la qualité du service du médecin, et il est donc tentant pour celui-ci d'utiliser cette capacité à induire la demande principalement sur les populations vulnérables. Il est notable que les HMO rationnent la qualité clinique sur ces populations, tout en laissant la qualité moyenne inchangée (Miller et Luft 1997).

L'arbitrage coût-qualité-équité : la capacité du médecin d'augmenter la prescription

L'adressage et la prescription sont des éléments importants de la pratique du médecin et des coûts totaux des soins de santé. En France, 33 % des séances auprès d'un médecin seraient motivées par une recommandation d'un autre médecin. Au Royaume-Uni, 5 % des séances auprès d'un médecin de première ligne donnent lieu à un adressage (Coulter 1992) et on observe une très forte variation des pratiques des médecins, dont les caractéristiques des patients ne rendent pas compte (résumé par Scott 2000).

Une théorie simple, mais robuste, du comportement du médecin montre que la capitation et le salariat incitent le médecin à transférer à d'autres son propre travail et à augmenter le volume prescrit pour diminuer l'effort non rémunéré (temps passé avec le malade, écoute, auscultation).

Les données empiriques confirment largement cette prédiction. L'étude de Krasnik et coll. (1990) montre que le passage des généralistes au paiement à l'acte a significativement réduit leur taux d'adressage et de prescription. Rappelons que cette étude dispose d'un échantillon contrôle dont le mode de paiement est resté inchangé au cours de la même période.

L'idée que le temps passé en consultation est plus court dans le mode de paiement à la capitation ressort des comparaisons internationales : d'après Sandier (1990), alors que le généraliste français, payé à l'acte, consacre quinze minutes (en 1979) en moyenne à chaque consultation, le généraliste anglais, payé à la capitation, se contente de huit minutes (en 1987). Cependant, à contexte homogène et pour des données individuelles, il n'est pas confirmé que la capitation ou le salariat diminue le temps de consultation : Kristiansen et Mooney (1993) trouvent même, avec des données norvégiennes, que les généralistes payés à l'acte passent moins de temps en consultation que les salariés, mais la différence est non significative.

Une solution pour éviter que la capitation n'augmente le coût des soins prescrits est de rendre le prescripteur responsable du budget total des soins pour une personne. Il s'agit d'une forme d'intégration verticale des soins, confiée au médecin de première ligne et que nous détaillerons ci-dessous.

Partie 2 :
À la recherche du mode de rémunération optimal : les enseignements d'une variété d'expériences

La question des incitations liées aux modes de paiement a reçu une attention croissante depuis que les systèmes de santé font face à des enjeux majeurs d'arbitrage entre coût, qualité et équité. Réformes générales ou expérimentations locales, diverses solutions ont été mises à l'essai pour concilier ces objectifs potentiellement contradictoires au niveau des mécanismes de rémunération des professionnels. Nous les passerons en revue dans cette partie, en distinguant plusieurs approches.

Une première tente de combiner des incitations variées au sein même de la rémunération individuelle des médecins, avec des systèmes de paiement mixtes comprenant forfait, capitation et paiement à l'acte. Des incitations financières particulières y sont éventuellement incorporées; parmi celles-ci les formes les plus novatrices sont des mécanismes d'intéressement au résultat, financier ou sanitaire (paiement à la performance).

Une deuxième élabore des systèmes d'incitation financière différents au niveau individuel et au niveau collectif de la profession médicale.

Les conflits d'intérêts qui en résultent conduisent à envisager cette formule non plus au niveau d'un collectif très large de professionnels, mais au sein de groupes plus restreints : c'est le sens d'une troisième approche, qui se développe aujourd'hui, et qui confie à des groupes de médecins la conciliation d'objectifs financiers et de qualité.

Enfin, une dernière voie de réflexion dans la recherche du meilleur rapport coût/qualité consiste à associer aux incitations financières des incitations d'un autre ordre, comme l'information fournie au médecin, ou l'élaboration de références de pratique et de divers moyens de les diffuser. La dimension collégiale de l'exercice médical peut favoriser cette évolution des pratiques et l'on retrouve, par ce biais, un intérêt potentiel des groupes ou des réseaux évoqués ci-dessus.

Combinaisons d'incitations au sein de la rémunération individuelle des médecins

Avant d'aborder les systèmes de paiement mixtes, notons qu'aucun mode de paiement n'a émergé comme une alternative globale aux « grands standards » que constituent le paiement à l'acte, la capitation et le salaire.

Le paiement par épisode de soins, transposé du paiement des hôpitaux au groupe homogène de malades (DRG), a été considéré par le programme Medicare aux États-Unis au milieu des années 80, mais il ne semble pas avoir eu beaucoup d'applications concrètes en médecine ambulatoire. Il est envisageable dans le cas des soins techniques pour des épisodes aigus,

par exemple un chirurgien percevant une rémunération globale pour la phase pré-opératoire, l'acte et le suivi post-opératoire (Robinson 2001a); il a été étudié en cardiologie, par exemple pour le pontage coronarien (Showstack, Garnick et Rosenfeld 1987). Mais l'extension de ce mode de paiement à l'ensemble de l'activité médicale soulève de nombreux problèmes techniques.

En termes d'applications pratiques, l'innovation et l'inventivité se sont donc plutôt manifestées au niveau de la façon d'agencer différents éléments de paiement et d'aménager des incitations à la marge pour une petite fraction de la rémunération.

Un exemple intéressant de paiement mixte est celui des généralistes anglais, dont la rémunération comprend (Redbook 2002) :

- Une allocation de base destinée à prendre en charge une fraction des coûts de fonctionnement, sous forme d'un forfait par patient dégressif en fonction du nombre de patients. Une allocation supplémentaire compense les surcoûts liés à l'exercice en région rurale. Des majorations sont également versées en fonction de l'expérience acquise par le médecin (honoraires dits « de séniorité »).
- Une capitation par patient inscrit sur la liste du généraliste, avec trois niveaux selon l'âge (moins de 65 ans, 65 à 74 ans et 75 ans et plus); les patients des zones défavorisées donnent aussi lieu à une capitation additionnelle, reflétant leurs besoins plus importants.
- Des paiements à l'acte pour les visites de nuit, les vaccinations, les consultations en urgence pour des patients de confrères, la petite chirurgie, ainsi que des honoraires spécifiques plus globaux pour le suivi de la contraception, la surveillance des jeunes enfants, la prise en charge des grossesses.
- Des paiements aux résultats (« *target payments* »), pour le dépistage du cancer du col utérin (paiement lié au taux de femmes ayant eu un frottis dans les cinq années précédentes), pour la couverture vaccinale des enfants de deux ans et celle des enfants d'âge pré-scolaire.

La part de la rémunération qui est indépendante du niveau de service représente 65 % (50 % pour la capitation et 15 % pour les allocations de base), les paiements à l'acte 25 % et les paiements à la performance 10 %. En outre, toujours au Royaume-Uni, les médecins travaillant dans les régions rurales mal desservies peuvent dispenser les médicaments à leurs patients; ils reçoivent alors des honoraires spécifiques.

Les paiements incitatifs ont-ils eu les résultats escomptés? Il semble effectivement que les activités rémunérées à l'acte aient augmenté la plupart du temps, mais pas toujours (par exemple la proportion de médecins acceptant des suivis de grossesses complets a diminué de 1960 à 1980). Par ailleurs, on ne peut faire la part, dans cette augmentation d'activité, du rôle de l'incitation financière et d'autres facteurs liés à l'évolution générale de la pratique professionnelle et de la demande des patients (Whynes et Baines 1998).

Si, dans le National Health Service (NHS), des incitations à la productivité sont venues s'ajouter aux paiements à l'origine forfaitaires, on assiste aujourd'hui à l'introduction de forfaits dans des systèmes de paiement à l'acte, par exemple :

- Au Québec, pour les spécialistes en milieu hospitalier, la rémunération mixte a consisté à introduire une part forfaitaire et, en contrepartie, à ne payer les actes qu'à une fraction de leur tarif et à supprimer la facturation d'actes annexes.
- En France, pour être « médecins référents » les généralistes volontaires se voient attribuer un forfait annuel de 46 Euros pour le suivi général du patient, en plus de la tarification à l'acte (mais cette option n'a été choisie que par 10 % des généralistes et 1 % des patients).

Les formes les plus innovatrices de paiement mixte intègrent des éléments d'intéressement aux résultats (paiement à la performance). Ces résultats peuvent être sanitaires (comme dans l'exemple britannique ci-dessus), mais aussi financiers, c'est-à-dire liés à la maîtrise des coûts. Ces incitations sont utilisées par les organisations de *managed care* aux États-Unis en vue de réduire les adressages aux spécialistes et les recours à l'hospitalisation. Elles sont en général fondées sur un intéressement du médecin à la performance financière de l'organisation. Quel bilan peut-on tirer des expériences d'intéressement aux résultats?

L'intéressement aux résultats financiers

La réforme de 1991 au Royaume-Uni (*fundholding*) a introduit un intéressement financier pour les généralistes britanniques en ce qui a trait aux dépenses de médicaments et de chirurgie programmée des patients inscrits sur leur liste : le généraliste volontaire recevait un budget en début de période pour tous ses patients, et pouvait conserver l'éventuel surplus en fin d'année. Théoriquement, les surplus ne sont pas un revenu, car le généraliste doit les réinvestir dans sa pratique; mais, en réalité, il est difficile de séparer le revenu personnel du médecin de celui de sa pratique. L'évaluation de cette expérience a montré que les médecins ont effectivement réalisé des économies sur les budgets de médicaments, mais peu sur la chirurgie programmée, l'une des raisons étant la position de quasi-monopole des hôpitaux britanniques (Coulter 1992).

Une étude de Debrock et Arnould (1992) a mesuré l'effet des incitations financières axées sur le médecin, en contrôlant à l'aide des incitations existant au niveau du groupe. Leurs conclusions, pour les 35 organisations de *managed care* de l'Illinois examinées entre 1985 et 1987, sont que les incitations financières individuelles ont réduit le taux d'admission à l'hôpital de 16 % et diminué de moitié le nombre de consultations par bénéficiaire.

Si l'intéressement des médecins à limiter les dépenses semble efficace, le conflit d'intérêts qu'il risque de poser entre l'éthique professionnelle et l'intérêt financier du praticien est mal perçu par la profession et surtout par la population :

- Une enquête auprès de 766 médecins américains, dont 58 % faisaient l'objet d'incitations au niveau collectif ou individuel, a révélé que 57 % des praticiens ressentaient une pression pour limiter les adressages et 17 % pensaient que cela pouvait influer

négativement sur la qualité de la prise en charge (Grumbach et coll. 1998, cités par Armour et coll. 2001). L'enquête donne aussi une idée des montants associés à ce genre de bonis : les médecins interrogés estimaient que les bonis représentaient environ 7 % de leur revenu médian.

- Bien que d'importance limitée, ces incitations financières inquiètent les patients, qui craignent qu'elles ne limitent l'autonomie professionnelle de leur médecin. Il y a peu d'indications empiriques sur l'étendue de cette préoccupation, si ce n'est les nombreux recours en justice portant sur les incitations financières offertes aux médecins. La législation américaine a d'ailleurs fixé en 1996 certaines limites aux contrats passés entre organisations de *managed care* et médecins et rendu leur publication obligatoire. Selon Hall, Dugan, Balkrishnan et coll. (2002), la publication des incitations accroîtrait légèrement la confiance des patients si le médecin est payé par capitation, mais n'aurait aucun effet s'il est rémunéré à l'acte.

De nombreux auteurs, assureurs et HMO pensent aujourd'hui qu'il faut utiliser des incitations à la performance pour accroître la qualité, en valorisant des objectifs sanitaires plutôt que financiers. Selon Rosser et Kasperski (2002), les médecins de l'Ontario se déclarent convaincus par le passage à la capitation à condition que celle-ci soit mitigée par une rémunération à l'acte pour certains services, comme les gardes, et des primes pour l'atteinte d'objectifs de prévention.

L'intéressement aux résultats sanitaires

Ces formules ne portent pas directement sur des objectifs de santé – idée séduisante mais difficilement praticable – mais sur la prise en charge de la population suivie. La prévention, primaire (vaccination) ou secondaire (dépistage) en est le domaine d'application le plus fréquent.

L'exemple du Royaume-Uni cité ci-dessus semble montrer que ces « *target payments* » ont un impact positif : selon le ministère de la santé du Royaume-Uni (cité par Scott et Hall 1995), la proportion de généralistes atteignant l'objectif fixé est passée en cinq mois, pour la vaccination, de 55 % à 70 % (objectif : taux de vaccination de 90 % ou de 70 %) et de 53 % à 67 % pour les frottis (objectif : 80 % des femmes de 25 à 64 ans ayant eu un frottis dans les cinq ans). Certes, cette simple observation de résultats « avant-après » ne permet pas de neutraliser les autres facteurs explicatifs possibles et d'affirmer de manière rigoureuse que l'augmentation est due à l'incitation financière. C'est ce que souligne Armour et coll. 2001 à propos d'une autre expérience, tentée en Irlande du Nord, pour la vaccination des enfants : là encore, bien que le taux de vaccination ait fortement augmenté sur cette période, l'effet pur de cette mesure n'est pas dégagé d'autres effets concomitants.

Une expérience de bonis pour améliorer le dépistage des cancers, mise en place par une organisation de *managed care* pour des bénéficiaires du programme Medicaid, a été évaluée (Hillman et coll. 1998). Un boni semestriel allant de 10 % à 20 % de la capitation pour l'ensemble des femmes bénéficiaires était versé aux six cabinets qui réalisaient le plus fort taux de dépistage. Cinquante-deux cabinets ont été répartis aléatoirement entre un groupe

d'intervention (avec incitation) et un groupe témoin. L'étude n'a pas révélé de différence significative dans les taux de dépistage entre les deux groupes.

À l'inverse, des conclusions positives sont ressorties d'une expérience d'incitation à la vaccination grippale des personnes âgées de plus de 65 ans portant sur cinquante-quatre cabinets new-yorkais et évaluée par un essai contrôlé (Kouides et coll. 1998). En plus de la rémunération pour le vaccin (8,00$), les médecins recevaient 0,80$ par vaccin au-delà d'un taux de vaccination de 70 % pour les 65 ans et plus et de 1,60$ pour un taux excédant 80 %. Le taux de vaccination dans le groupe avec boni (69 %) était supérieur de 6 points de pourcentage à celui du groupe témoin, et 52 % des cabinets recevant le boni avaient atteint un taux de vaccination de 70 %, contre 44 % dans le groupe témoin. Une analyse neutralisant un certain nombre de facteurs environnementaux permet aux auteurs de conclure que l'introduction des bonis a permis d'augmenter de 7 % le taux de vaccination des personnes âgées.

Il semble qu'une tendance récente consiste à lier le boni à plusieurs indicateurs de qualité. Dans une expérience menée par Aetna (Hanchak 1997), les groupes de médecins contractants ont reçu des bonis en fonction de leur score sur un indice de qualité des soins intégrant plusieurs dimensions, dont la satisfaction du patient, l'adéquation des traitements et l'efficience. Les auteurs concluent à un effet positif sur toutes les dimensions de la qualité (baisse de 2 % du taux de césarienne, baisse de 25 % de la durée moyenne des séjours à l'hôpital, augmentation de 85 % des biopsies et taux de certification approchant 95 % à la fin du programme), à l'exception de la satisfaction du patient qui ne semble pas avoir augmenté.

En conclusion d'une revue de la documentation, Armour et coll. (2001) notent que les résultats des études sur l'effet des incitations sont contradictoires et permettent difficilement de porter un jugement définitif. Par contre, ils notent que les études traitent rarement à la fois d'effets de quantité et d'effets de qualité et ils y voient la reconnaissance d'une forme d'arbitrage entre la maîtrise des coûts et la qualité de soins.

Combinaisons d'incitations différentes au niveau individuel et collectif

Une deuxième approche consiste à tenter, non pas de contrebalancer différents incitatifs au sein de la rémunération individuelle, mais de compenser les incitations individuelles par des incitations collectives.

Elle s'illustre par exemple dans les systèmes d'enveloppe limitative globale associée au paiement à l'acte. L'Allemagne a opté pour un tel système dès le début des années 80 et d'autres pays ou régions ont adapté ce principe, selon des modalités variables en fonction de leur contexte propre.

Les médecins allemands sont rémunérés à l'acte mais soumis au principe d'une modération collective : les paiements à l'acte de l'ensemble des médecins d'un Land sont plafonnés, et le montant est réparti entre les praticiens par les syndicats de médecins, au prorata de l'activité de

chacun, exprimée en points sur une nomenclature d'actes. En d'autres termes, la valeur unitaire du point n'est pas connue à l'avance mais est déduite *a posteriori* en divisant l'enveloppe totale par le nombre cumulé de points de tous les médecins (Busse 2000).

La rémunération directe des praticiens par les caisses, sous forme de paiement cumulé sur une période donnée (trimestre en Allemagne) conditionne le caractère opératoire d'un tel système. Cependant, des systèmes où ces conditions ne sont pas remplies ont aussi instauré des plafonds de dépenses (Québec, France, États-Unis pour Medicare) : la différence est que l'ajustement sur le tarif unitaire ne peut se faire automatiquement en temps réel, mais doit être décidé – et négocié – pour l'année suivante, en fonction des résultats constatés. Cette modalité a évidemment toutes les chances d'être moins efficace sur le plan du strict respect de l'enveloppe financière.

En théorie, ce type de mécanisme suscite un conflit, pour chaque médecin, entre l'intérêt collectif à une modération quantitative (une valeur du point plus élevée et un niveau de revenu globalement inchangé pour quantité de travail moindre) et l'intérêt individuel qui reste de maximiser son volume d'activité propre à un prix unitaire donné. Il favorise donc les comportements de type « passager clandestin », chaque médecin se disant qu'il pourra profiter à titre personnel de la modération collective s'il augmente son volume d'activité, ce qui au total conduit à une inflation des volumes contrairement à l'objectif recherché.

Cela est lié, évidemment, à la dilution de la responsabilité au sein d'un collectif très important. Individuellement, chaque médecin n'a aucune chance d'influer sur la valeur unitaire par un comportement vertueux, mais il a, au contraire, tout intérêt à être ce « passager clandestin » du grand collectif anonyme. Nous reviendrons sur la question de la taille des groupes de médecins ci-dessous.

Les attendus théoriques de ce genre de système – inflation continue des volumes et baisse corrélative des prix unitaires – semblent bien confirmés par l'observation en Allemagne (encore que l'on puisse débattre, s'agissant de l'augmentation des volumes, de la part liée à ces comportements opportunistes des médecins ou à d'autres facteurs – demande, progrès technique, etc.).

Il faut donc un mécanisme complémentaire pour contrebalancer cette incitation à des comportements individuels trop « productivistes ». Celui-ci peut relever :

- Du contrôle : Il est présent en Allemagne, où l'activité individuelle est examinée par les médecins des caisses. Au passage, on peut penser que ce contrôle sera d'autant plus efficace qu'il est organisé par la profession elle-même; la faisabilité de ces dispositifs dépend de la disposition du corps médical à co-gérer la contrainte financière avec les régulateurs, comme le montre *a contrario* l'exemple français.
- De l'incitation, comme au Québec, avec des tarifs dégressifs au-delà d'un seuil quantitatif d'actes, ce qui écrête les très fortes activités.

Le groupe de médecins comme lieu d'intégration des objectifs cliniques et économiques

Dans différents pays, on assiste, semble-t-il, à une évolution convergeant vers un exercice médical plus collectif, sous des diverses formes – réseaux, groupes monodisciplinaires ou groupes pluridisciplinaires.

Cette évolution émerge, depuis le milieu des années 90, dans des contextes nationaux aussi contrastés que le NHS anglais et le *managed care* américain (Bocognano et coll. 1998). Au Royaume-Uni, la réforme de 1997, en instituant les *Primary Care Groups* ou *Trusts* (PCG/T), a généralisé les premiers regroupements spontanés de généralistes *fundholders*; dans les contextes locaux les plus concurrentiels aux États-Unis, des groupes de médecins se sont développés très rapidement, pour passer des contrats avec les assureurs en soins de santé cherchant à constituer des réseaux, voire dans les cas extrêmes intégrer eux-mêmes les fonctions de l'assureur.

Dans les deux cas, la perspective est de faire de ces groupes des réseaux très structurés, possédant leur propre infrastructure de gestion.

Ces groupes se voient parfois confier une responsabilité financière et une délégation de gestion. Ainsi les PCG/T britanniques sont-ils rémunérés par des paiements globaux, à charge pour eux de répartir le financement entre les différents cabinets médicaux qui les composent. Prenant la suite de l'expérience des *fundholders*, les budgets alloués englobent non seulement la rémunération des médecins, mais aussi les prescriptions et les hospitalisations.

Les PCG/T sont donc à la fois responsables du respect d'un budget global, des arbitrages entre différentes composantes de ce budget, et de la répartition des honoraires et budgets de prescription entre leurs membres.

Pour cela, ils doivent développer une expertise leur permettant d'optimiser l'utilisation des ressources. Ainsi, dans le domaine de la prescription médicamenteuse, tous les PCG/T surveillent les prescriptions de leurs membres à l'aide des tableaux indicatifs fournis par le palier national, presque tous ont un conseiller pharmaceutique, 70 % utilisent des référentiels communs de prescription et 49 % ont produit leur propre formulaire (Wilkin, Gillam et Coleman, 2000/2001).

Cet exemple illustre l'intérêt des groupes de médecins, qui réside dans la possibilité de lier la responsabilité financière et la gouvernance clinique dans un collectif :

- Géré par les professionnels, et ayant donc à la fois la compétence technique pour faire les meilleurs choix et une éthique de la qualité.
- De taille suffisante pour se doter d'un certain nombre d'outils d'expertise et d'évaluation et, en même temps, de taille suffisamment restreinte pour que chaque professionnel se sente impliqué.

L'engouement pour les groupes médicaux, jugés les mieux aptes à mettre en œuvre une gestion efficiente des processus de soins, et dès lors de concilier qualité des soins et utilisation

économe des moyens, a également été très fort dans le système de *managed care* américain. Dans les zones les plus concurrentielles, on a vu durant la deuxième moitié des années 90 un développement très rapide de ces groupes médicaux et de leur capacité de gestion et de négociation, tant avec les assureurs en amont qu'avec les hôpitaux en aval.

Au sein de ces réseaux, des groupes par spécialité peuvent se voir attribuer des budgets globaux dont ils gèrent la répartition entre les praticiens individuels. Ceux-ci peuvent être payés à l'acte, mais le groupe met en place des procédures (revue par les pairs, vérification de l'utilité des soins, etc.) qui sont plus opérationnelles au sein d'une même spécialité que dans des groupes multidisciplinaires (Robinson 2001b). Dans ce cadre, peuvent être mis en œuvre des mécanismes de capitation, dits « capitation de contact », assez novateurs pour des spécialistes : dès qu'un patient est confié par un généraliste à un médecin du groupe, celui-ci reçoit une capitation pour une durée de 12 mois, durée pendant laquelle il prend en charge le patient comme il l'entend.

Ce principe de rémunération est plus adapté aux spécialités dont l'activité est à peu près homogène (cardiologie, gastro-entérologie, etc.). Il peut être rajusté pour tenir compte de la lourdeur des cas, par exemple en pondérant les effectifs de patients pour certains diagnostics ou certains actes, ou en prévoyant la rémunération à l'acte pour certaines procédures (Franck 1999). Ce mode de paiement a été utilisé dans plusieurs HMO et les spécialistes du *managed care* lui prédisaient récemment un bel avenir (Carlson 1997). L'expérience suédoise semble confirmer que l'incitation collective peut avoir un profond impact, même si le revenu individuel n'est pas touché par le changement de mode de paiement : certains hôpitaux sont passés à un mode de paiement à la pathologie, alors que d'autres conservaient l'enveloppe annuelle fixe; mais, dans les deux cas, les médecins étaient salariés de l'hôpital. Il en résulte que les médecins des hôpitaux rémunérés à la pathologie ont notablement réduit les durées de séjour, même si le coût total n'a pas diminué dans ces hôpitaux (Forsberg, Axelsson et Arnetz 2001).

Les expériences décrites ci-dessus concernent des réseaux très formalisés ayant de fortes délégations de responsabilité. Mais l'idée de promouvoir un exercice plus collectif de la médecine, sous forme de réseaux ou de groupes, se développe également dans d'autres systèmes, de manière moins structurée (France, Allemagne, certaines provinces canadiennes avec les expériences de groupes de médecine familiale). Dans ce cas, l'objectif est plutôt d'améliorer la coordination et la continuité des soins, qu'une pratique individuelle et rémunérée à l'acte ne favorise pas spontanément. Mais l'idée sous-jacente est la même : entre le médecin isolé et la profession dans son ensemble, le groupe de médecins, localement implanté, partageant des compétences et une culture commune, peut être un levier de changement des pratiques dans le sens recherché.

Cependant, l'évolution récente aux États-Unis donne à réfléchir sur les excès de cette tendance. La Californie, « royaume du groupe médical », a connu ces dernières années plusieurs faillites et voit aujourd'hui les groupes se défaire et la contractualisation individuelle reprendre de l'ampleur. Le recul des groupes va de pair avec le recul de la capitation comme mode de paiement (Managed Care Outlook 2001) : le pourcentage des groupes ayant au moins un contrat à la capitation, qui était en hausse entre 1998 et 1999 (66 % à 72 %) a fléchi en 2000 (55 %).

Les facteurs qui expliquent la fragilité des groupes et leur absence de pérennité (déséconomies d'échelle, difficulté à intégrer des logiques d'assurance, demande de libre choix des patients, etc.) montrent bien que la conciliation des objectifs de maîtrise des coûts et de qualité par la vertu de la « gouvernance clinique » collective a ses limites et qu'une responsabilisation financière extrême n'est peut-être pas le moyen le plus propice de tirer le meilleur parti de ces organisations collectives qui paraissent malgré tout, dans beaucoup de systèmes, constituer une voie de progrès.

Incitations non financières

Si les groupes de médecins peuvent harmoniser la maîtrise des coûts et la qualité des soins, ce n'est pas seulement par l'alchimie des incitations financières collectives et individuelles auxquelles ils sont confrontés : c'est bien parce qu'ils associent aux incitations financières d'autres mécanismes incitatifs.

Ceux-ci sont de plusieurs ordres. Le premier instrument est l'**élaboration et la diffusion de protocoles cliniques et de recommandations,** aujourd'hui communes à la plupart systèmes publics ou privés. Ils peuvent être nationaux ou locaux, avoir un caractère indicatif ou obligatoire (formulaires pour les médicaments, par exemple). L'efficacité comparée des différentes modalités de diffusion des références (formation, entretiens, rappels informatiques) sur leur application par les médecins a fait l'objet d'une abondante documentation, suite aux recommandations de la *Cochrane Collaboration on Effective Professional Practice*. Il serait trop long de restituer et de commenter cette documentation dans le cadre du présent rapport, mais nous pouvons en retenir les enseignements principaux, tels que résumés par Durieux (1998) : aucune étude ne décèle d'impact significatif de la diffusion de normes par matériel imprimé ou par formation médicale continue; en revanche, la diffusion par des leaders d'opinion, ou, mieux encore, par des visites confraternelles a un impact significatif sur les pratiques des médecins.

En congruence avec ce premier résultat, **l'évaluation de la pratique individuelle**, notamment au regard de ces référentiels, ou par rapport aux confrères (restitution d'information au médecin, revue par les pairs, etc.) est un levier de modification des comportements individuels.

Le réseau de soins ou le groupe de médecins constitue un niveau privilégié d'application de ces incitations, pour les raisons invoquées ci-dessus. Ce sera d'autant plus le cas que ces réseaux sélectionnent leurs membres en fonction de leur adhésion aux valeurs du groupe – sur les plans clinique, économique et culturel. Un pas supplémentaire peut être franchi dans les systèmes à assureurs multiples avec le **conventionnement sélectif** (capacité pour le payeur de ne prendre en charge qu'un nombre limité de professionnels), qui constitue évidemment une puissante incitation non financière.

Conclusion :
Quels enseignements pour le contexte canadien?

Le Canada occupait la cinquième place des pays de l'OCDE en 1998 pour la part du PIB consacrée aux dépenses de santé, et le rapport intermédiaire de la Commission sur l'avenir des soins de santé au Canada note que le problème réside plutôt dans l'instabilité de l'évolution de ces dépenses que dans leur niveau absolu (OCDE 2001, Commission 2002).

Toujours en 1998, le Canada se classait au septième rang pour les dépenses en soins ambulatoires par personne, avec un niveau (333$PPA) représentant le tiers de celui des États-Unis, 80% de celui de l'Allemagne, mais supérieur de 40 % à celui de la France. L'évolution des prix des services de médecins au Canada sur la décennie 1985-1996 coïncide avec celle d'autres pays de l'OCDE (à l'exclusion des États-Unis) et la progression des volumes, assez forte au début par comparaison avec les autres pays, semble avoir été freinée à partir de 1995.

Le Canada ne semble donc pas se distinguer par un problème spécifique de maîtrise des coûts des soins de santé[6]. En revanche, le rapport intermédiaire de la Commission souligne la grande insatisfaction des Canadiens au regard de l'accessibilité et de la qualité du système de soins.

Pour résoudre ces problèmes, faut-il remettre en cause la rémunération à l'acte? On a vu que le paiement par capitation peut faire peser un risque sur la qualité des soins et l'accessibilité, d'autant plus que le médecin ne redoute pas la concurrence, par exemple en cas de pénurie de médecins. Par contre, en modulant la rémunération du médecin selon le type de population qu'il dessert, la capitation peut permettre de traiter des problèmes particuliers comme la répartition géographique inégale des médecins sur le territoire.

Le débat actuel sur l'avenir du système de santé canadien est sans doute l'occasion d'un débat sur le mode de paiement. D'autant que d'après le dernier sondage réalisé par l'Association médicale canadienne, si 62 % d'entre eux tirent la quasi-totalité de leurs revenus de paiements à l'acte, seulement 37 % préfèrent ce mode de rémunération aux autres modes (Martin 2000).

Questions spécifiques

Quel est l'impact des mécanismes de paiement des médecins aussi bien sur l'utilisation des services médicaux que sur l'utilisation générale et les coûts globaux du système de santé?

Comment le paiement à l'acte des médecins influence-t-il l'utilisation et les coûts du système par rapport à d'autres mécanismes de paiement, et quelles sont les différences que l'on peut observer à ce chapitre?

Il n'existe pas de réelle alternative aux systèmes de paiements canoniques que sont le paiement à l'acte, la capitation et le salariat. Les innovations récentes en sont plus des adaptations à la marge. On synthétise l'état des connaissances sur l'impact des modes de paiement sur les coûts des soins, selon leur degré de forfaitisation : le paiement à l'acte permet au médecin d'augmenter le volume des services médicaux qu'il fournit au patient, et limite donc la portée des modes de régulation par les prix unitaires.

À l'inverse, les paiements forfaitisés (capitation et salariat) limitent les volumes, mais peuvent peser sur la qualité des soins rendus, limiter l'accès aux soins pour les populations vulnérables et avoir des conséquences imprévues sur le niveau des dépenses. L'ampleur de l'impact sur la qualité et l'accès dépend de manière cruciale de la capacité du patient d'observer l'effort du médecin, capacité sur laquelle il est difficile de se prononcer empiriquement. L'effet imprévu sur les coûts passe par la prescription (la forfaitisation incite le médecin de première ligne à adresser et prescrire plus) et par les effets à long terme (si le médecin réduit le service à court terme, le système peut en payer les conséquences à long terme).

Les réponses concrètes apportées visent à combiner les mécanismes, de façon à ce que les défauts se compensent. Les paiements en fonction de résultats sanitaires (objectifs intermédiaires) permettent notamment d'améliorer la capacité du mode de paiement à la capitation de tenir compte de la diversité du travail du médecin, et de combiner des objectifs de santé publique, d'une part, et d'accès et de qualité, de l'autre. Les délégations de responsabilité à la profession médicale (le régulateur fixe une enveloppe, gérée ensuite de manière décentralisée) se heurtent à des comportements opportunistes si la décentralisation est trop faible, et à des conflits d'intérêts si elle est trop poussée (groupes de médecins trop restreints). Après avoir été présentée comme la solution de l'avenir, la délégation à des groupes de médecins semble aujourd'hui marquer le pas, au profit des incitations non financières, centrées sur l'information du patient et du médecin.

De quelles données dispose-t-on sur l'impact des changements en matière de mécanismes de paiement ou de mesures incitatives sur l'utilisation et les coûts? Où et comment se produisirent les changements les plus marqués?

Les données quantitatives sont rares, opportunistes (on utilise des expériences faites pour d'autres buts) et toujours affectées de biais. Les changements exogènes notables se sont produits au Royaume-Uni, avec l'introduction du *fundholding* et des PCT, au Danemark (expérience de Copenhague) et en Allemagne (enveloppe et point flottant). Aux États-Unis, il y a eu de

nombreuses expériences sur des échantillons réduits (une clinique ou un régime), qui sont difficilement généralisables. La réforme des tarifs de Medicare a aussi constitué un terrain d'expérimentation, mais la difficulté principale est qu'on mêle niveau et mode de rémunération.

Il ressort des données quantitatives empiriques que le passage de la capitation au paiement à l'acte augmente les volumes et diminue la prescription, sans qu'on ait de preuve réelle de l'effet réciproque. Le bilan sur la qualité est plus ambigu, même si la satisfaction des patients semble défavorable au régime forfaitaire. Les expériences de paiement au résultat semblent modérément concluantes quant à l'impact des incitations sur le résultat recherché. Outre les évaluations quantitatives, on trouve des bilans qualitatifs, basés sur les opinions des acteurs; le suivi conjoncturel de l'histoire des groupes de médecins aux États-Unis et de leurs arrangements internes fournit de nombreux résultats, qui sont toutefois difficilement généralisables à des contextes où il n'y a qu'un seul payeur.

> *Quelles sont les mesures incitatives non monétaires qui peuvent affecter l'utilisation et les coûts du système? Comment fonctionnent-elles?*

Deux innovations principales sont proposées : aider les médecins en leur fournissant une information validée et synthétisée sur les protocoles cliniques et l'efficience, notamment en remplaçant la promotion provenant de l'industrie des biens médicaux et aider les médecins et les patients à se faire une idée de la variation des pratiques. Ce deuxième genre d'incitation permet de renforcer le contrôle des patients sur l'effort du médecin, ce qui peut augmenter la variabilité (adaptation des pratiques à la demande) ou la diminuer (standardisation). Mais il ne s'agit pas seulement de nommer et de dénoncer; les médecins peuvent aussi trouver avantage à comparer leur pratique à celles de leurs confrères. L'impact des ces incitations non monétaires dépend fortement du contexte, notamment du degré d'organisation de la profession et de la capacité des médecins de diffuser la conformité aux normes de bonnes pratiques parmi leurs pairs.

Figure 1
Évolution des prix et des volumes* des services de médecins, 1985-1996

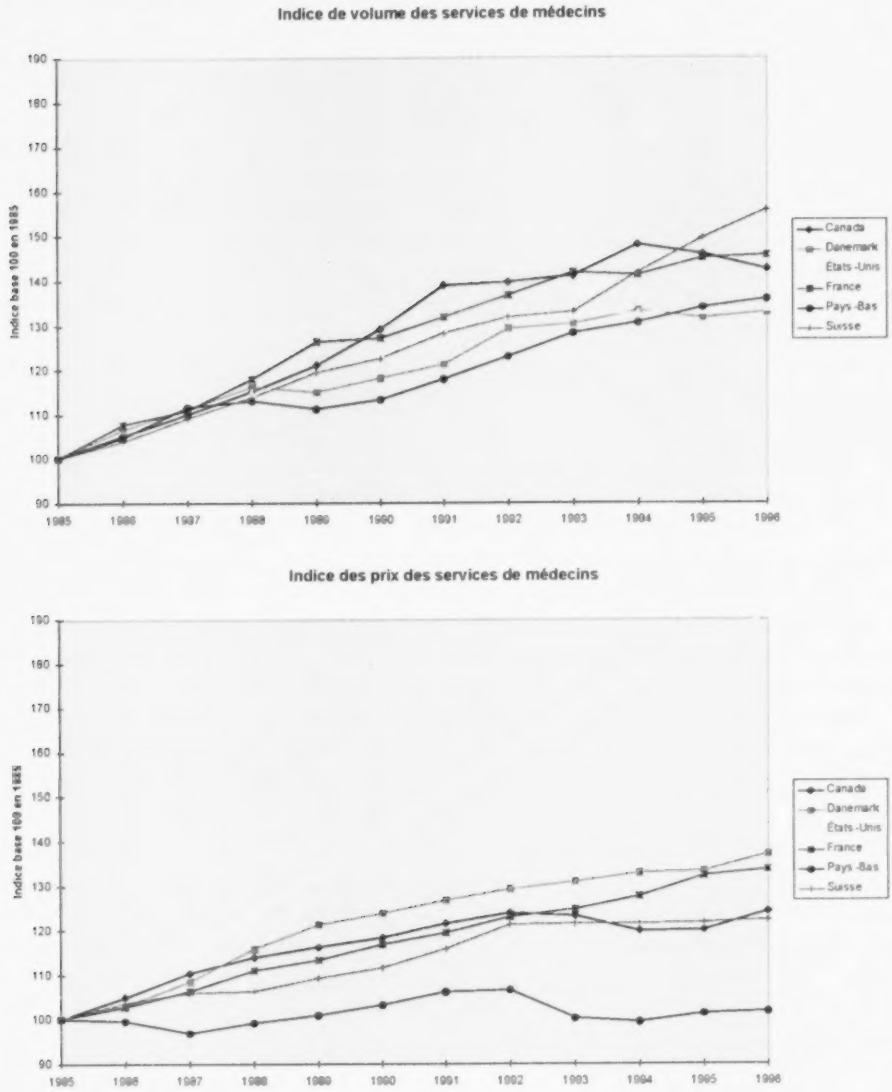

* Les volumes correspondent aux dépenses en soins de médecins ambulatoires, déflatées par l'indice de prix correspondant.
Source : OCDE, 2001.

Notes

1 Augmenter la quantité peut signifier modifier la structure des services offerts, en augmentant la part des actes mieux rémunérés. Rochaix (1993) montre, en prenant l'exemple québécois entre 1977 et 1983, que les gels d'honoraires ont conduit à une augmentation significative de la part des consultations dites « lourdes ».

2 En régime salarial, le médecin peut éventuellement être sanctionné par son employeur. Dans le cas de la capitation, il sera sanctionné par le patient si la sous-qualité est perçue et si les professionnels sont en situation de concurrence pour attirer la clientèle.

3 L'adressage est l'action par laquelle un professionnel dirige son patient vers un autre professionnel.

4 Ces données permettent de contrôler les biais dans les études par comparaisons en captant les effets propres à chaque individu; en revanche, parce qu'il s'agit de données complexes à obtenir, les échantillons sont moins souvent représentatifs.

5 Une autre étude sur le même ensemble de données montrerait un impact significatif et important du paiement à l'acte sur le volume d'examens d'urine (Kristiansen et Hjortdahl 1992). Mais Scott et Hall (1995) soulignent que cet effet est mesuré sans corriger le biais lié à la non indépendance des observations (on observe plusieurs contacts par patient).

6 Ce diagnostic repose sur les données disponibles au moment de la rédaction de cet article (c'est-à-dire 1996 ou 1998 selon les séries). Il est possible que les experts canadiens portent un autre jugement à la lumière de données plus récentes sur l'évolution des dépenses, des prix et des volumes produits.

Bibliographie

Armour, Brian S., et coll. 2001. The effect of explicit financial incentives on physician behaviour, *Archives of Internal Medicine*, 161(10), 1261-1266.

Bocognano Agnès, et coll. 1998. *Mise en concurrence des assurances dans le domaine de la santé : théorie et bilan des expériences étrangères*, CREDES-INSEE.

Brunelle, Yvon, et Howard Bergman. 1999. Capitation, efficience et rationnement, *Ruptures, revue transdisciplinaire en santé*, 6(2), 270-288.

Busse, Rheinardt. 2000. *Health Systems in Transition – Germany*, European Observatory on Health Care Systems.

Carlson, Bob. 1997. "Capitation: State of the art", <httpwww.managedcaremag.com/archives>.

Commission sur l'avenir des soins de santé au Canada. 2002. *Préparer l'avenir des soins de santé*, Rapport d'étape, février.

Coulter, Angela. 1992. The interface between primary and secondary care, dans *Hospital Referrals*, sous la direction de M. Roland et A. Coulter, Oxford General Practices Series 22, Oxford University Press.

Davidson, Stephen, M. Manheim, S, Werner et coll. 1992. Prepayment with office-based physicians in publicly funded programs: results from the children's Medicaid program, *Pediatrics*, 89, 761-767.

Debrock, Larry, et Richard J. Arnould. 1992. Utilization control in HMOs, *Quarterly Review of Economic Finance*, 32, 31-53.

Durieux, Pierre. 1998. Les actions de diffusion et de formation, dans *Comment améliorer les pratiques médicales? Approche comparée internationale*, sous la coordination scientifique de Pierre Durieux, Institut d'Études des Politiques de Santé, 11-18.

Emery, J.C. Herbert, Chris Auld et Mingshan Lu. 1999. *Paying for physician services in Canada: The institutional, historical and policy context*, Institute of Health Economics, Working Paper 99-6.

Escarce, José. 1996. Using physician practice cost functions in payment policy: the problem of endogeneity bias, *Inquiry*, 33, 66-78.

Epp, Michael, et coll. 2000. The impact of direct and extra billing for medical services: Evidence from a natural experiment in British Columbia, *Social Science and Medicine*, 51, 691-702

Evans, Robert, G. 1974. Supplier induced demand: Some empirical evidence and implications, dans *The Economics of Health and Medical Care* McMillan, sous la direction de M. Perlman 162-173.

____. 1998. New bottles, old wine: right and wrong in physician supply, *Canadian Medical Association Journal*, 158, 757-759.

Ferrall, Christopher, Allan W. Gregory et William G. Tholl. 1998. Endogenous work hours and practice patterns of Canadian physicians, *Revue canadienne d'économique*, 31(1), 1-27.

Forsberg, Ewa, Runo Axelsson et Arnetz Bengt, 2001, Financial incentives in health care. The impact of performance-based reimbursement, *Health Policy* 58(3): 243-262.

Franck, Clifford R. 1999. Can the pie be divided more fairly?, *Contact capitation for specialists*, 5(2), http://www.cost-quality.com/5,2art3.html.

Gerdtham, Ulf-G., Jes Sogaard, Fredrik Andersson et Bengt Jönsson. 1992. Econometric analysis of health expenditure: A cross-section study of the OECD countries *Journal of Health Economics*, 11, 63-84.

Gerdtham, Ulf-G, Bengt Jönsson, M. MacFarlan et H. Oxley. 1998. The determinants of health expenditure in OECD countries, dans *Health, the Medical Profession, and Regulation*, sous la direction de Peter Zweifel, Kluwer.

Gillett, James, Brian Hutchison et Stephen Birch. 2001. Capitation and primary care in Canada: Financial incentives and the evolution of health service organizations, *International Journal of Health Services*, 31(3), 583-603.

Glied, Sherry. 1998. Payment Heterogeneity, Physician Practice, and Access to Care, *American Economic Review*, 88(2), 127-131.

Gosden, Toby, Frode Forland, Ivar Sombo Kristiansen et coll. 2001. Impact of payment method on behaviour of primary care physicians: A systematic review, *Journal of Health Services Research and Policy*, 10(1), 44-55.

Grumbach, Kevin, Dennis Osmond, Karen Vranizan et coll. 1998. Primary care physicians' experience of financial incentives in managed care systems, *New England Journal of Medicine*, 339, 1516-1521.

Grytten, Jostein, et Rune Sorensen. 2001. Type of contract and supplier-induced demand for primary physicians in Norway, *Journal of Health Economics*, 20, 379-393.

Hall, Mark, A., Elizabeth Dugan, Rajesh Balkrishnan et coll. 2002. How Disclosing HMO Physician Incentives Affects Trust, *Health Affairs*, 21(2), 19-27.

Hanchak, N. A. 1997. A performance-based compensation model for obstetricians/gynecologists, *Clinical Obstetrics and Gynecology*, 40, 437-445.

Hemenway, David. 1995. Financial incentives for childhood immunization, *Jounal of Policy Analysis and Management*, 14, 133-139.

Hickson, B., A. Altemeier, et M. Perrin. 1987. Physician reimbursement by salary of fee-for service: Effect on physician practice behaviour in a randomized prospective study, *Pediatrics*, 80, 344-350.

Hillman, Alan, L., Kimberly Ripley, Neil Goldfard et coll. 1998. Physician financial incentive and feedback: Failure to increase cancer screening in Medicaid managed care, *American Journal of Public Health*, 88, 1699-1701.

Hutchinson, James M., et Robert N. Foley. 1999. Method of physician remuneration and rates of antibiotic prescription, *Canadian Medical Association Journal*, 160, 1013-1017.

Jelovac, Izabela. 2001. Physicians' payment contracts, treatment decisions and diagnosis accuracy, *Health Economics*, 10, 9-25.

Josseran, L., G. King et J. Chaperon. 2000. Les primary care physicians américains, *Journal d'économie médicale*, 18(6), 375-387.

Kouides, R.W., N.M. Benett, B. Lewis, J.D. Cappuccio, WH. Barker et F.M. LaForce. 1998. Performance-based physician reimbursement and influenza immunization rates in the elderly, *American Journal of Preventive Medicine*, 14, 89-95.

Kralewski John E. et coll. 2000. The Effects of Medical Group Practice and Physician Payment Methods on Costs of Care, *Health Services Research*, 35(3), 591-613.

Krasnik, Allan P. Groenwegen et Poul-A. Pedersen. 1990. Changing remuneration system: Effects on activity in general practice, *British Medical Journal*, 300, 1698-1701.

Kristiansen, Iwar S., et K. Holtedahl. 1993. The effect of the remuneration system on the general practitionner's choice between surgery consultations and home visits, *Journal of Epidemiology and Community Health*, 47, 481-484.

Kristiansen, Iwar S., et Gail Mooney. 1993. The general practitioner's use of time: Is it influenced by the remuneration system?, *Social Science and Medicine*, 37, 393-399.

Kristiansen, Iwar S., et Per Hjortdahl. 1992. The general practitioner and laboratory utilization: Why does it vary?, *Family Practice*, 9, 22-27.

Managed Care Outlook. 2001. "Interest in capitation back off", <http://www.managedcaremag.com/archives>.

Mc Guire, Thomas G. 2000. Physician agency dans *Handbook of Health Economics*, sous la direction de Anthony J. Culyer et Joseph P. Newhouse volume 1, p. 463-536.

Martin, Shelley. 2000. CMA survey shows fee-for-service not dead yet, *Canadian Medical Association Journal*, 163(5), 601.

Miller, Robert H., et Harold S. Luft. 1997. Does managed care lead to better or worse quality of care?, *Health Affairs*, 16(5), 7-25.

Mulligan, Pamela. 2002. La capitation : une direction mal avisée dans la réforme des soins de première ligne, *Le Médecin de famille canadien*, 48, 244-246.

Namovicz-Peat, S., J. Swann et K. Tureski. 2001. *HMO & PBM Strategies for Pharmacy Benefits: Recent Results, Current Practices, Future Plans*, AIS - Atlantic Information Services.

OCDE, 2001. *Eco-santé OCDE 2001*, CREDES-OCDE.

Philips, Karen, et William R. Swan. 1996. *Health care system in transition: Canada*, version préliminaire, Organisation mondiale de la santé – Bureau régional pour l'Europe, Copenhague.

Pricewhaterhouse Coopers LLP. 2001. *Study on Pharmaceutical Benefit Management*, disponible sur le site de Health Care Financing Administration.

Redbook 2002. http://www.nhs.uk/redbook/2.htm.

Rice, Thomas. 1993a. A model is only as good as its assumptions: A reply to Peele. *Journal of Health Economics* , 12, 209-211.

_____. 1993b. Demand curves, economists, and desert islands: A response to Feldman and Dowd. *Journal of Health Economics* , 12, 201-204.

Robinson, James C. 2001a. Theory and practice in the design of physician payment incentives, *The Milbank Quarterly*, 79(2), 148-177.

Robinson, James C. 2001b. Physician organization in California: Crisis and opportunity, *Health Affairs*, 20(4), 81-96.

Rochaix, Lise. 1993. Financial Incentives for Physicians: the Quebec Experience, *Health Economics*, 2, 163-176.

Rosser, Walter, et Jan Kasperski. 2002. En faveur d'une rémunération mixte, *Le Médecin de famille canadien*, 48, 247-249.

Sandier, Simone. 1990. Le paiement des médecins dans quelques pays de l'OCDE, dans *Les systèmes de santé, A la recherche d'efficacité*, Paris, OCDE, 1990.

Santé Canada. 2001. Loi canadienne sur la santé, *Rapport annuel 2000-2001*.

Scott, Anthony, et Jane Hall. 1995. Evaluating the effects of GP remuneration: problems and prospects, *Health Policy*, 31, 183-195.

Scott, Anthony. 2000. Economics of general practice, dans *Handbook of Health Economics*, sous la direction de Anthony J. Culyer et Joseph P. Newhouse volume 1, p.1175-1200.

Showstack, Jonathan A., Deborah W. Garnick, Kenneth E. Rosenfeld et coll. 1987. Episode-of-care physician payment: A study of coronary artery bypass graft surgery, *Inquiry*, 24, 376-383.

Stearns, Sally C., Barbara L. Wolfe et David A. Kindig. 1992. Physician responses to fee-for-service and capitation payment, *Inquiry*, 29, 416-429.

Tai-Seale, Ming, Thomas H. Rice and Sally C. Stearns. 1998. Volume responses to Medicare payment reductions with multiple payers: A test of the McGuire-Pauly model, *Health Economics*, 7, 199-219.

Whynes, David, et Darrin L. Baines. 1998. Income-based incentives in UK general practice, *Health Policy*, 43, 15-31.

Wilkin, David, Steve Gillam et Anna Coleman. 2000/2001. *The national tracker survey of primary care groups and trusts*, www.kingsfund.org.uk.